

#### Thèse de doctorat

pour l'obtention du grade de

Docteur de l'Université Paris-Est

#### Spécialité Informatique Linguistique

au titre de l'École Doctorale MSTIC

Présentée et soutenue publiquement par

#### Elsa Tolone

le 31 mars 2011

# Analyse syntaxique à l'aide des tables du Lexique-Grammaire du français

#### Devant le jury composé par :

Rapporteurs: Laurence Danlos (Université Denis Diderot - Paris 7)

Laura Kallmeyer (Universität Düsseldorf)

Examinateurs: Éric de La Clergerie (INRIA Paris-Rocquencourt)

Denys Duchier (Université d'Orléans)

Directeur de thèse : Éric Laporte (Université Paris-Est)

Co-directeur de thèse: Matthieu Constant (Université Paris-Est)

#### Remerciements

Avant tout, je tiens à remercier les membres du jury, Laurence Danlos, Laura Kallmeyer, Éric de la Clergerie et Denys Duchier, d'avoir accepté d'évaluer mon travail et pour leur commentaires enrichissants.

Je remercie également mon directeur de thèse, Eric Laporte, pour toutes ses précieuses remarques, notamment lors de la rédaction de mon travail.

Sans oublier mon co-directeur, Matthieu Constant, pour m'avoir conseillé durant mon travail et son aide pour certains outils.

L'aide de Christian Leclère a été pour moi d'une importance capitale puisqu'il est l'auteur principal des tables de verbes et qu'il a bien voulu m'accorder le temps nécessaire pour démystifier toutes mes interrogations.

Ma collaboration avec Stavroula Voyatzi m'a permis également d'aborder les expressions figées et les adverbes avec beaucoup plus de facilité.

Enfin, Benoît Sagot m'a énormément aidé quand à la comparaison des deux formats de lexiques et pour les outils de conversion.

Un grand merci à Éric de la Clergerie pour sa réactivité et l'adaptation de son analyseur syntaxique à mon lexique.

Certains doctorants ont également jouer un rôle important :

- Kyriaki Ioannidou avec son optimisme exemplaire et ses questions acharnées qui m'ont permis d'envisager la poursuite de ce travail pour le grec,
- Wankawee Puangkor avec sa gentillesse et son aide à me dépatauger parmi la masse de fiches cartonnées,
- Myriam Rakho et Antony Sigogne avec l'utilisation du fruit de mon travail dans d'autres applications,
- enfin, aussi bien les doctorants de Paris-Est, de Paris 7, de Nancy, que de la FaMAF m'ont permis de partager de bons moments lors de ces dernières années.

Merci à Noémi Boubel et son équipe du CENTAL, ainsi qu'à Paul Sabatier et son équipe du LIF pour leur accueil chaleureux et leur intérêt lors de mes séminaires.

Je souhaiterais également remercier Tita Kyriacopoulou, qui a su me donner goût à la linguistique, lorsqu'en licence j'ai suivi son cours tout à fait par hasard, et qui grâce à son dynamisme et à ses discussions passionnantes, m'a aidée à choisir ma voie.

Pour finir, je souhaiterais remercier tous mes relecteurs que j'ai déjà cités pour la plupart : j'ajouterais Lidia Varga, ainsi que mes parents, qui ont tous les deux eu le courage de lire ma thèse jusqu'au bout.

Enfin, merci à toute ma famille et à tous mes amis pour m'avoir soutenue durant toutes ces années.

#### Résumé

Les tables du Lexique-Grammaire, dont le développement a été initié par Gross (1975), constituent un lexique syntaxique très riche pour le français. Elles couvrent diverses catégories lexicales telles que les verbes, les noms, les adjectifs et les adverbes. Cette base de données linguistiques n'est cependant pas directement exploitable informatiquement car elle est incomplète et manque de cohérence.

Chaque table regroupe un certain nombre d'entrées jugées similaires car elles acceptent des propriétés communes. Ces propriétés ont pour particularité de ne pas être codées dans les tables mêmes mais uniquement décrites dans la littérature. Pour rendre ces tables exploitables, il faut expliciter les propriétés intervenant dans chacune d'entre elles. De plus, un grand nombre de ces propriétés doivent être renommées dans un souci de cohérence.

Notre objectif est d'adapter les tables pour les rendre utilisables dans diverses applications de Traitement Automatique des Langues (TAL), notamment l'analyse syntaxique. Nous expliquons les problèmes rencontrés et les méthodes adoptées pour permettre leur intégration dans un analyseur syntaxique.

Nous proposons LGExtract, un outil générique pour générer un lexique syntaxique pour le TAL à partir des tables du Lexique-Grammaire. Il est relié à une table globale dans laquelle nous avons ajouté les propriétés manquantes et un unique script d'extraction incluant toutes les opérations liées à chaque propriété devant être effectuées pour toutes les tables. Nous présentons également LGLex, le nouveau lexique syntaxique généré des verbes, des noms prédicatifs, des expressions figées et des adverbes.

Ensuite, nous montrons comment nous avons converti les verbes et les noms prédicatifs de ce lexique au format Alexina, qui est celui du lexique Lefff (Lexique des Formes Fléchies du Français) (Sagot, 2010), un lexique morphologique et syntaxique à large couverture et librement disponible pour le français. Ceci permet son intégration dans l'analyseur syntaxique FRMG (French MetaGrammar) (Thomasset et de La Clergerie, 2005), un analyseur profond à large couverture pour le français, basé sur les grammaires d'arbres adjoints (TAG), reposant habituellement sur le Lefff.

Cette étape de conversion consiste à extraire l'information syntaxique codée dans les tables du Lexique-Grammaire. Nous présentons les fondements linguistiques de ce processus de conversion et le lexique obtenu. Nous évaluons l'analyseur syntaxique FRMG sur le corpus de référence de la campagne d'évaluation d'analyseurs du français Passage (Produire des Annotations Syntaxiques à Grande Échelle) (Hamon et al., 2008), en comparant sa version basée sur le Lefff avec notre version reposant sur les tables du Lexique-Grammaire converties.

#### **Abstract**

Lexicon-Grammar tables, whose development was initiated by Gross (1975), are a very rich syntactic lexicon for the French language. They cover various lexical categories such as verbs, nouns, adjectives and adverbs. This linguistic database is nevertheless not directly usable by computer programs, as it is incomplete and lacks consistency.

Tables are defined on the basis of features which are not explicitly recorded in the lexicon. These features are only described in literature. To use these tables, we must make explicit the essential features appearing in each one of them. In addition, many features must be renamed for consistency sake.

Our aim is to adapt the tables, so as to make them usable in various Natural Language Processing (NLP) applications, in particular parsing. We describe the problems we encountered and the approaches we followed to enable their integration into a parser.

We propose *LGExtract*, a generic tool for generating a syntactic lexicon for NLP from the Lexicon-Grammar tables. It relies on a global table in which we added the missing features and on a single extraction script including all operations related to each property to be performed for all tables. We also present *LGLex*, the new generated lexicon of French verbs, predicative nouns, frozen expressions and adverbs.

Then, we describe how we converted the verbs and predicatives nouns of this lexicon into the Alexina framework, that is the one of the Lefff lexicon (Lexique des Formes Fléchies du Français) (Sagot, 2010), a freely available and large-coverage morphological and syntactic lexicon for French. This enables its integration in the FRMG parser (French MetaGrammar) (Thomasset et de La Clergerie, 2005), a large-coverage deep parser for French, based on Tree-Adjoining Grammars (TAG), that usually relies on the Lefff.

This conversion step consists in extracting the syntactic information encoded in Lexicon-Grammar tables. We describe the linguistic basis of this conversion process, and the resulting lexicon. We evaluate the FRMG parser on the reference corpus of the evaluation campaign for French parsers Passage ( $Produire\ des\ Annotations\ Syntaxiques\ \grave{a}\ Grande\ \acute{E}chelle$ ) (Hamon  $et\ al.,\ 2008$ ), by comparing its Lefff-based version to our version relying on the converted Lexicon-Grammar tables.

### Table des matières

| 1  | Introduction |  |     |
|----|--------------|--|-----|
|    | 1.1          | Contexte   | 13  |
|    | 1.2          | Objectif   |     |
|    | 1.3          | Plan de la thèse   | 15  |
| I  | Ét           | at de l'art  | 17  |
| 2  | Les          | analyseurs syntaxiques et les lexiques syntaxiques                             | 19  |
|    | 2.1          | Analyse syntaxique   | 19  |
|    | 2.2          | Lexiques syntaxiques   | 26  |
| 3  | Les          | tables du Lexique-Grammaire  | 33  |
|    | 3.1          | Notations du Lexique-Grammaire   | 33  |
|    | 3.2          | Point de départ : Les tables du Lexique-Grammaire                              | 38  |
| 4  | Le l         | exique syntaxique ${ m Le} {\it fff}$ et l'analyseur syntaxique ${ m FRMG}$    | 45  |
|    | 4.1          | Le lexique syntaxique Lefff et le format Alexina                               | 45  |
|    | 4.2          | L'analyseur syntaxique FRMG  | 52  |
| 11 | M            | odifications des tables  | 63  |
| 5  | Ame          | élioration des tables et création des tables des classes                       | 65  |
|    | 5.1          | Provenance des tables et état des lieux  | 65  |
|    | 5.2          | Format d'origine et classification   | 68  |
|    | 5.3          | Formalisation et homogénéisation des propriétés syntaxico-sémantiques .        | 79  |
|    | 5.4          | Tables des classes   | 83  |
|    | 5.5          | Codage des tables  | 86  |
|    | 5.6          | Bilan  | 93  |
| 6  | Con          | structions de base pour toutes les catégories                                  | 95  |
|    | 6.1          | Les classes des verbes distributionnels : Les complétives et les infinitives . | 96  |
|    | 6.2          | Les classes des verbes distributionnels de BGL                                 | 100 |
|    | 6.3          | Les classes des noms prédicatifs   | 112 |

#### Table des matières

|     | 6.4<br>6.5<br>6.6               | Les classes des expressions figées   | . 138   |
|-----|---------------------------------|--|---|
| Ш   | Co                              | nversion des tables  | 153   |
| 7   | 7.1<br>7.2<br>7.3<br>7.4<br>7.5 | version au format $LGLex$ MotivationsL'outil $LGExtract$ Le lexique $LGLex$ Le script de $LGExtract$ Discussion  | <ul><li>. 157</li><li>. 161</li><li>. 167</li></ul> |
| 8   | <b>Con</b> 8.1 8.2              | version au format Lefff  Conversion du lexique $LGLex$ en un lexique au format Alexina Le lexique $LGLex$ -Lefff |   |
| IV  | Ré                              | sultats  | 193   |
| 9   | <b>Réca</b> 9.1 9.2 9.3         | Bilan sur l'avancement des travaux de conversion   | . 195   |
| 10  | 10.1<br>10.2<br>10.3<br>10.4    | gration dans FRMG et évaluation Intégration dans l'analyseur syntaxique FRMG Évaluation et discussion            | <ul><li>206</li><li>209</li><li>210</li></ul>       |
| 11  | 11.1                            | Clusion et perspectives  Conclusion  |   |
| Bil | oliogi                          | raphie   | 229   |
| V   | An                              | inexes   | 241   |
| Α   | A.1                             | nat du lexique $LGLex$ Description of the content of the $LGLex$ lexicon   |   |

| В | Génération du lexique $LGLex$ à l'aide de $LGExtract$                                 | 253 |
|---|---|-----|
| С |   | 258 |
| D | Génération du lexique $LGLex$ - $Lefff$ à l'aide de $LGLex2ilex$                      | 263 |
| Ε | Documentation des propriétés des tables de verbes distributionnels                    | 265 |
| F | Formules définitoires des tables de verbes distributionnels                           | 309 |
| G | Arbre de classement des verbes distributionnels G.1 Conventions de lecture de l'arbre |     |

Table des matières

# Introduction

#### 1.1 Contexte

L'analyse syntaxique de textes à l'aide de lexiques syntaxiques est au centre de projets de recherche récents sur le français :

- Mosaïque (2006-2007, INRIA) sur le développement de modèles syntaxiques de haut niveau, en considérant, en particulier, la notion de méta-grammaire;
- EVALDA-EASy (2003-2005, Technolangue) sur la mise en place d'une campagne d'évaluation d'analyseurs syntaxiques;
- LexSynt (2005-2007, Institut de la Langue Française) sur le développement de modèles linguistiques pour les lexiques syntaxiques et sémantiques, ainsi que sur la constitution d'un lexique de référence pour le français;
- Passage (2007-2009, ANR) sur la construction automatique d'un très gros corpus annoté en syntaxe par l'utilisation et l'évaluation de plusieurs analyseurs syntaxiques, ainsi que sur l'acquisition d'informations linguistiques et extra-linguistiques à partir de ce corpus;
- Séquoïa (2009-2011, ANR) sur les analyseurs syntaxiques probabilistes à large couverture pour le français;
- EDyLex (2010-2012, ANR) sur l'acquisition dynamique de nouvelles entrées dans des lexiques existants, utilisés au sein de chaînes d'analyse syntaxique et sémantique complètes.

La construction de lexiques syntaxiques n'existe pas que pour le français, des projets existent depuis les années 1990 pour l'anglais.

Le projet *ComLex Syntax* (Grishman *et al.*, 1994) a pour objectif la création d'un lexique syntaxique à large couverture pour l'anglais. La première version de ComLex Syntax a été diffusée par le Linguistic Data Consortium (LDC) en 1994 et la version

finale en 1997. Il s'est poursuivi par la création de *NomLex* (Macleod *et al.*, 1997), un lexique sur les nominalisations de verbes avec une première version publiée en 1999, sa dernière version datant de 2001.

FrameNet (Baker et al., 1998) est un projet fondé sur la sémantique des cadres. Il a pour objectif de documenter la combinatoire syntaxique et sémantique pour chacun des sens d'une entrée lexicale à travers une annotation manuelle d'exemples choisis dans des corpus sur des critères de représentativité lexicographique. Il a débuté en 1997 et se poursuit actuellement.

Citons pour terminer, VerbNet (Kipper et al., 2000), un lexique des classes de verbes anglais, qui est la ressource la plus proche du Lexique-Grammaire. VerbNet regroupe par classe les verbes partageant les mêmes comportements syntaxiques et sémantiques. C'est un prolongement des travaux de Levin (1993). De nouvelles versions sortent régulièrement, la version actuelle datant de 2009.

Les tables du Lexique-Grammaire du français (Gross, 1975) constituent une base de données riche et détaillée contenant des informations lexicales, syntaxiques et sémantiques. Elles couvrent diverses catégories lexicales telles que les verbes, les noms, les adjectifs et les adverbes. Chaque table regroupe les éléments lexicaux d'une catégorie lexicale donnée, partageant certaines propriétés syntaxico-sémantiques. Leur développement a été initié depuis plus de quarante ans par M. Gross, au sein du Laboratoire d'Automatique Documentaire et Linguistique (LADL), puis du Laboratoire d'Informatique Gaspard-Monge (LIGM) de l'Université Paris-Est. Mais elles n'ont pas été créées en un format permettant directement leur utilisation dans un programme informatique tel qu'un analyseur syntaxique.

#### 1.2 Objectif

L'objectif de cette thèse est de permettre aux données linguistiques codées dans les tables du Lexique-Grammaire de servir de base de données lexicales pour diverses applications de Traitement Automatique des Langues (TAL), notamment un analyseur syntaxique automatique du français. Pour cela, nous avons converti les tables au format Alexina, qui est celui du lexique Lefff, un lexique syntaxique à large couverture pour le français (Sagot et Danlos, 2007; Sagot, 2010), présenté au chapitre 8. En effet, ce format est directement utilisable dans les applications de TAL de haut niveau, y compris celles qui nécessitent une analyse syntaxique profonde.

Parmi les analyseurs qui prennent en entrée un lexique au format Alexina, nous avons choisi l'analyseur FRMG, un analyseur profond à large couverture pour le français (Thomasset et de La Clergerie, 2005), avec une description grammaticale de haut niveau sous la forme de méta-grammaire. Nous avons donc réalisé l'intégration des tables dans cet analyseur, afin d'évaluer leur impact lors d'une l'analyse au chapitre 10.

Avant d'être converties au format Lefff, nous avons converti les tables en un format

d'échange, reposant sur les mêmes concepts linguistiques que ceux qui sont manipulés dans les tables. Nous proposons l'outil générique, nommé LGExtract, qui permet de générer un lexique syntaxique pour le TAL à partir des tables du Lexique-Grammaire. Il est relié à une table globale, appelée table des classes, dans laquelle nous avons ajouté les propriétés manquantes, et à un unique script d'extraction incluant toutes les opérations liées à chaque propriété devant être effectuées pour toutes les tables. Nous présentons cet outil, ainsi que le lexique obtenu, appelé LGLex, au chapitre 7. Le format du lexique LGLex a vocation à décrire les tables avec les concepts manipulés par celles-ci, en un format directement exploitable dans les applications de TAL. L'une des utilisations informatiques possibles est la conversion en un autre format, par exemple au format Lefff, ce qui suppose de manipuler d'autres concepts linguistiques, ceux manipulés par le Lefff.

Mais en premier lieu, nous avons dû modifier les tables pour les rendre directement exploitables, ce qui est détaillé dans les chapitres 5 et 6. En effet, les propriétés communes à chaque table ont pour particularité de ne pas être codées dans les tables mêmes mais uniquement décrites dans la littérature. Pour rendre ces tables exploitables, il faut expliciter les propriétés intervenant dans chacune d'entre elles. De plus, un grand nombre de ces propriétés doivent être renommées dans un souci de cohérence. Nous expliquons les problèmes rencontrés et les méthodes adoptées lors de cette étape d'homogénéisation. Le but étant que les tables soient entièrement corrigées et complétées afin de former un tout cohérent avec notamment une description précise de chaque propriété syntaxico-sémantique et une définition formelle pour chaque table.

Les tables gardent leur raison d'être, car elles sont dans un format facilement manipulable par des linguistes n'étant pas informaticiens. En effet, le format tabulaire facilite le codage car les entrées sont faciles à identifier visuellement et à comparer.

Les tables d'origine sous format papier constituent la version 1. Après avoir été récupérées sous format électronique (Excel), 60% des tables ont été mises en ligne en 2002, ce qui constitue la version 2. Cette thèse a donné jour à la version 3 en septembre 2008, version qui évolue régulièrement. Elle inclut toutes les modifications effectuées sur les tables disponibles, ainsi que les lexiques auxquels elles ont été convertis (*LGLex* et *LGLex*-Lefff). Diffusée le 31 mars 2011, la version 3.3 contient la totalité des tables, avec de plus une documentation complète de toutes les propriétés syntaxico-sémantiques des verbes distributionnels, ainsi que la définition formelle de chaque table et l'arbre de classement des verbes distributionnels.

#### 1.3 Plan de la thèse

Le chapitre 2 (Les analyseurs syntaxiques et les lexiques syntaxiques) évoque l'analyse syntaxique, l'évaluation d'analyseurs lors de la campagne Passage, ainsi que les lexiques syntaxiques.

Le chapitre 3 (Les tables du Lexique-Grammaire) présente les motivations initiales de la création des tables du Lexique-Grammaire. Des exemples de tables sont

donnés et l'ensemble des notations utilisées sont décrites. Les tables constituent le point de départ de notre travail.

Le chapitre 4 (Le lexique syntaxique Lefff et l'analyseur syntaxique FRMG) décrit le format TAL dans lequel nous avons converti les tables. Il s'agit du format Alexina, qui est celui du lexique syntaxique Lefff, utilisé par l'analyseur FRMG, dont nous expliquons en détail le fonctionnement.

Le chapitre 5 (Amélioration des tables et création des tables des classes) se penche sur les tables du Lexique-Grammaire, l'intérêt de leur format et les améliorations que nous y avons apportées. Nous mettons en avant le format d'origine des tables, tout en expliquant leur classification. Un inventaire précis des tables est établi, ce qui nous permet de soulever l'origine des problèmes de cohérence qu'elles contiennent. Puis, nous expliquons comment nous avons formalisé et homogénéisé les propriétés syntaxico-sémantiques, en listant les différentes solutions apportées. Enfin, nous définissons ce qu'est une table des classes en expliquant son rôle, et nous détaillons le codage qu'il reste encore à faire.

Dans le chapitre 6 (Constructions de base pour toutes les catégories), nous décrivons toutes les constructions de base qui ont été modifiées pour l'ensemble des catégories, à savoir les verbes distributionnels, les noms prédicatifs, les expressions figées et les adverbes.

Le chapitre 7 (Conversion au format LGLex) présente l'outil LGExtract, ainsi que son script associé, permettant de convertir les tables de l'ensemble des catégories au format LGLex.

Le chapitre 8 (Conversion au format Lefff) explique comment nous avons effectué la conversion des verbes et des noms prédicatifs du lexique LGLex au format Lefff, tout en détaillant les fondements linguistiques et la méthodologie pratique de cette conversion. Enfin, la conversion des expressions figées est abordée également.

Dans le chapitre 9 (Récapitulatif des travaux effectués) nous faisons un bilan sur l'avancement des travaux de conversion des tables, ainsi que sur l'évolution de la version 3 des tables. Enfin, nous montrons un extrait de la table 31R dans tous les formats disponibles actuellement.

Le chapitre 10 (Intégration dans FRMG et évaluation) montre comment le lexique a été couplé avec l'analyseur syntaxique FRMG, dont nous justifierons le choix, et évalue cet analyseur sur le corpus de référence de la campagne d'évaluation Passage, en comparant sa version basée sur le Lefff avec notre version reposant sur les entrées des verbes simples et des noms prédicatifs des tables du Lexique-Grammaire converties.

Le chapitre 11 (Conclusion et perspectives) dresse un bilan du travail effectué sur les tables du Lexique-Grammaire du français afin de les rendre exploitables dans des analyseurs syntaxiques. Puis, nous évoquons l'extension de ce travail à d'autres langues, telles que le grec, afin de construire un lexique syntaxique à partir des tables du Lexique-Grammaire du grec. Enfin, nous terminons par quelques pistes afin d'améliorer le lexique LGLex-Lefff du français et son intégration dans FRMG.

### Première partie État de l'art

# 2

## Les analyseurs syntaxiques et les lexiques syntaxiques

Ce chapitre évoque l'analyse syntaxique et l'évaluation d'analyseurs lors de la campagne Passage dans la section 2.1, ainsi que les lexiques syntaxiques dans la section 2.2.

#### 2.1 Analyse syntaxique

Cette section situe l'analyse syntaxique en 2.1.1, puis présente la campagne d'évaluation Passage en 2.1.2, et fait une description succincte de quelques analyseurs syntaxiques du français en 2.1.3.

#### 2.1.1 Introduction

Dans le domaine du Traitement Automatique des Langues (TAL), l'analyse syntaxique constitue un point clé dans un grand nombre de traitements automatiques, tels que la compréhension de texte, l'extraction d'information ou la traduction. Le but d'un analyseur syntaxique est de pouvoir construire la structure syntaxique d'une phrase donnée en entrée. Autrement dit, sa tâche est de déterminer pour chaque terme de la phrase sa fonction syntaxique, ainsi que les relations de dépendance syntaxique des éléments de la phrase, telles que sujet-verbe ou verbe-objet. C'est une tâche difficile, en raison de la complexité et de la richesse de la langue. Depuis l'analyseur syntaxique développé par l'équipe de Z. Harris dans les années 50 (Joshi et Hopely, 1996), de nombreux progrès ont été réalisés.

Pour simplifier, on peut classer les différentes approches en deux catégories :

 les analyseurs symboliques qui utilisent une grammaire et/ou un lexique développés manuellement;  les analyseurs probabilistes qui reposent sur un modèle acquis à partir d'un corpus annoté manuellement.

L'analyse syntaxique probabiliste profonde obtient ses meilleurs résultats avec le formalisme des grammaires hors-contextes probabilistes (PCFG, *Probabilistic Context-Free Grammar*). Différentes stratégies d'apprentissage sont utilisées : soit lexicalisées (par exemple, Collins (2003)), soit non lexicalisées (par exemple, Klein et Manning (2003)). Notons, pour le français, que des travaux ultérieurs (Crabbé et Candito, 2008) corroborent en grande partie les résultats obtenus sur l'anglais.

L'approche symbolique, bien que laborieuse puisque les ressources sont développées manuellement, permet de construire une base très riche d'informations linguistiques. Il s'agit notamment de décrire les caractéristiques syntaxiques des mots, même si représenter toutes ces données est difficile. Cela induit des modifications importantes si les bons choix de formalisation ne sont pas réalisés dès le départ. C'est dans ce contexte que nous nous plaçons, l'objectif étant de montrer comment nous avons rendu cohérente et avons complété une base de données lexicales, les tables du Lexique-Grammaire, afin d'en faire une ressource utilisable dans les applications de TAL (Tolone, 2009).

#### 2.1.2 Campagne d'évaluation Passage

La campagne d'évaluation Passage (2007-2009) <sup>1</sup> (Hamon *et al.*, 2008) fait suite aux campagnes GRACE (1994-1998) <sup>2</sup> et EASy (2003-2006) <sup>3</sup> (Paroubek *et al.*, 2006). Elle reprend plusieurs des protocoles d'évaluation de cette dernière campagne, avec des corpus sensiblement différents et plus étendus.

Les principaux objectifs de cette campagne soutenue par l'ANR sont les suivants :

- évaluer les analyseurs du français;
- améliorer l'exactitude et la robustesse des analyseurs du français sur des corpus à grande échelle (270 millions de mots);
- exploiter les annotations syntaxiques résultantes pour créer une ressource linguistique plus riche et plus étendue : un treebank pour le français.

Six types de constituants ont été choisis pour cette campagne : groupe nominal, (GN), noyau verbal (NV), groupe adjectival (GA), groupe adverbial (GR), groupe prépositionnel (GP) et groupe prépositionnel à noyau verbal (PV).

Les relations (dépendances entre mots pleins) à relever sont les suivantes : dépendance sujet-verbe (SUJ-V), dépendance auxiliaire-verbe (AUX-V), objet direct (COD-V), autre complément du verbe (CPL-V), modifieur du verbe (MOD-V), subordonnée (COMP), attribut du sujet ou de l'objet (ATB-SO), modifieur du nom (MOD-N), modifieur de l'adjectif (MOD-A), modifieur de l'adverbe (MOD-R), modifieur de la préposition (MOD-P), coordination (COORD), apposition (APPOS) et juxtaposition (JUXT). La Fig. 2.1 donne un exemple d'annotation d'une phrase littéraire (Paroubek et al., 2008).

Le guide d'annotation utilisé lors des campagnes EASy et Passage est le guide des

<sup>1.</sup> http://atoll.inria.fr/passage/index.fr.html

<sup>2.</sup> http://www.limsi.fr/TLP/grace/

<sup>3.</sup> http://www.technolangue.net/article.php3?id\_article=198




FIGURE 2.1: Annotation d'une phrase littéraire extraite du corpus EASy

annotations syntaxiques de référence PEAS, disponible sur le site http://www.limsi.fr/Individu/anne/Guide/PEAS\_reference\_annotations\_v2.2.html.

Les métriques d'évaluation utilisées sont celles définies à l'occasion de la campagne EASy: la précision, le rappel et la f-mesure, avec différents modes de relâchement de contrainte sur la mesure des frontières de constituants (Paroubek *et al.*, 2006).

Pour la première campagne Passage de 2007, la référence utilisée est un extrait d'environ un million de mots du corpus EASy (Paroubek et al., 2006), de styles variés (journalistique, médical, oral, questions, littéraire, etc.), dont 4 306 phrases constituaient déjà la référence annotée de la campagne EASy en 2004 et 400 nouvelles phrases ont été annotées manuellement depuis. La Tab. 2.1 contient quelques phrases tirées du corpus.

| Genre          | Exemple de phrase  |
|----------------|--|
| Journalistique | Le gouvernement intérimaire a décidé d'asphyxier économiquement le «Tay-           |
|                | lorland», en imposant un embargo total sur les marchandises à destination des      |
|                | zones sous contrôle du FNLP.   |
| Littéraire     | Longtemps j'ai été comme eux, et j'ai souffert du même malaise.                    |
| Médical        | La sensibilité de l'échotomographie pour la définition des calculs vésiculaires de |
|                | plus de 2mm de diamètre est de 98% environ.  |
| Parlementaire  | - Monsieur le Président, mes chers collègues, je tiens simplement à faire un       |
|                | rappel au Règlement.   |
| Mails          | Alors moi je dis chapeau bas pour tes explications mon Jean.                       |
| Oral           | euh l'intervention c'est quoi  |

Table 2.1: Exemples de phrase par genre dans le corpus EASy

Le corpus Passage pour cette première campagne est composé de :

- Wikipedia (200K mots) : encyclopédique collaboratif libre;
- Wikinews (18.2K mots) : journalistique libre;
- Wikilivres (170K mots) : littéraire libre;
- Europarl (200K mots) : débat Parlementaire européen;
- JRC-Acquis (120K mots) : juridique européen;

```
Ester (100K mots): oral transcrit;
Le Monde (100K mots): journalistique.
corpus EASy (1M mots): multi-styles:
Le Monde (86K mots): journalistique;
Parlementaire (82K mots);
Littéraire (230K mots);
DELIC (9K mots): oral transcrit;
Ester (12K mots): oral transcrit;
Médical (50K mots);
Questions (52K mots);
Web (17K mots);
Mails (150K mots).
```

Les analyseurs syntaxiques ayant participés à la campagne d'évaluation Passage sont les suivants :

- FRMG, un analyseur syntaxique hybride TIG/TAG dérivé à partir d'une métagrammaire, développé à l'INRIA (de La Clergerie, 2005b; Thomasset et de La Clergerie, 2005);
- SxLFG, un analyseur syntaxique basé sur LFG, développé à L'INRIA (Boullier et Sagot, 2005);
- LLP2, un analyseur syntaxique TAG aussi dérivé à partir d'une méta-grammaire, développé au LORIA (Roussanaly et al., 2005);
- LIMA, un analyseur syntaxique basé sur des systèmes de règles, développé au LIC2M / CEA-LIST (de Chalendar et Nouvel, 2009);
- TagParser, un analyseur syntaxique hybride probabiliste/symbolique, développé par Gil Francopoulo à TAGMATICA (Francopoulo, 2008);
- ShP1 et StP1, deux analyseurs syntaxiques basés sur les grammaires de propriétés, développés au LPL et utilisant les satisfactions de contraintes. Le premier est symbolique et déterministe, alors que le second est probabiliste et entraîné grâce aux résultats de l'analyseur syntaxique pendant la campagne EASy (Vanrullen et al., 2006);
- Cordial, un analyseur syntaxique commercial basé sur des systèmes de règles, développé par Synapse (Laurent et al., 2009);
- SYGMART, un analyseur syntaxique développé au LIRMM (Béchet, 2009);
- XIP, un analyseur syntaxique commercial basé sur des cascades de règles, développé par Xerox (Aït-Mokhtar *et al.*, 2002).

Lors de la première évaluation de la campagne Passage qui s'est déroulée fin 2007<sup>4</sup>, 10 analyseurs ont fourni leurs résultats en constituants et seulement 7 ont pu être évalués sur les relations.

Pour l'annotation en constituants, la f-mesure est supérieure à 90% pour la plupart

<sup>4.</sup> Les résultats de la seconde campagne d'évaluation qui s'est déroulée fin 2009 ne sont pas encore disponibles.

des systèmes et seulement celle de trois systèmes est entre 80% et 90%. La tendance est à peu près la même pour la précision et le rappel. En ce qui concerne les relations, les performances sont moins bonnes que pour les constituants, et la différence entre les différents systèmes est supérieure, étant donné que la tâche est plus complexe. Aucun système n'a une performance au-dessus de 70% en f-mesure, trois sont en-dessous de 60% et deux en-dessous de 50%. Les deux derniers systèmes sont en-dessous de 40%.

#### 2.1.3 Quelques analyseurs syntaxiques pour le français

Détaillons à présent les différents analyseurs syntaxiques ayant participés à la campagne d'évaluation Passage.

#### **FRMG**

FRMG (FRench MetaGrammar) (de La Clergerie, 2005b; Thomasset et de La Clergerie, 2005) est un analyseur syntaxique profond pour le français. Une description grammaticale de haut niveau sous forme de méta-grammaire sert de point de départ pour la génération d'une grammaire d'arbres adjoints (TAG, Tree Adjoining Grammar) (Joshi et al., 1975; Abeillé, 2002). Cette grammaire est transformée par le système DyALog (de La Clergerie, 2005a; de La Clergerie, 2002) en un analyseur syntaxique.

L'analyseur syntaxique FRMG découlant des phases de compilation de la métagrammaire FRMG ne peut bien sûr fonctionner seul. Il s'intègre dans une chaîne complète de traitement comprenant, en amont, le lexique syntaxique Lefff et les nombreux modules de SxPipe (Sagot et Boullier, 2008) en charge de la segmentation, de la correction orthographique et de la détection des entités nommées.

L'analyseur syntaxique FRMG et le lexique syntaxique Lefff seront détaillés dans les sections 4.1 et 4.2.

#### **SXLFG**

SxLFG (Boullier et Sagot, 2005) est un analyseur syntaxique qui repose sur une variante du modèle des grammaires lexicales fonctionnelles (LFG, Lexical-Functional Grammars). Le moteur de SxLFG est un analyseur hors-contexte général qui traite la grammaire support de la LFG. L'ensemble des analyses qu'il produit est représenté sous la forme d'une forêt partagée. L'évaluation fonctionnelle se fait dans une seconde phase au cours d'un parcours bas-haut de cette forêt. L'entrée de l'analyseur est un automate acyclique de mots transformé par le lexeur en un automate acyclique de lexèmes, qui sont les terminaux de la grammaire hors-contexte (CFG, Context-Free Grammar) et les structures fonctionnelles sous-spécifiées associées. Un post-traitement (facultatif) permet alors de désambiguïser.

L'analyse de la grammaire support est réalisée par une évolution de l'analyseur Earley : il prend en entrée des automates acycliques de mots et permet de récupérer les erreurs syntaxiques. Traiter un automate acyclique en entrée ne nécessite pas, d'un point de vue

théorique, des changements considérables à l'algorithme Earley, même aidé d'un guide régulier.

#### LLP2

LLP2 (Roussanaly et al., 2005) est un analyseur syntaxique profond développé en Java, qui s'appuie sur une grammaire d'arbres adjoints lexicalisés (LTAG, Lexicalized Tree Adjoining Grammar) (Joshi et al., 1975). L'algorithme implémenté est celui de l'analyse par connexité. L'intégration d'un module de traitement de structures de traits et d'unification, permet de prendre en compte les traits top et bottom aux nœud des LTAG. En d'autres termes, LLP2 a la capacité de traiter des grammaires FTAG (Featured-based TAG) (Vijay-Shanker, 1987).

Du point de vue des ressources, LLP2 s'inspire de l'architecture XTAG qui distingue le lexique morphologique (permettant d'étiqueter les segments et d'identifier les lemmes correspondants), le lexique syntaxique (qui permet la sélection des arbres par filtrage et leur ancrage) et la grammaire (qui contient les arbres TAG).

Le lexique morphologique est majoritairement construit à partir de MULTEXT (Ide et Véronis, 1994). Le lexique syntaxique est extrait du lexique fourni par L. Clément et utilisé par l'analyseur XLFG (Clément, 2001). Un mécanisme par défaut de sélection des arbres élémentaires sur la base de règles reposant sur les traits morphologiques a été mis en place pour pallier les insuffisances du lexique syntaxique.

La grammaire a été engendrée à l'aide d'une méta-grammaire conçue par Benoît Crabbé (Crabbé, 2005) et compilée avec l'outil XMG développé au LORIA (Duchier et al., 2005).

#### **LIMA**

L'analyseur LIMA (*LIC2M Multilingual Analyzer*) (de Chalendar et Nouvel, 2009) est implémenté comme un pipeline de modules indépendants appliqués successivement sur un texte. Il met en œuvre une grammaire de dépendance, en ce sens que les analyses produites sont exclusivement représentées comme des relations de dépendance binaire entre les tokens. L'analyseur comprend, entre autres modules, un segmenteur en tokens reposant sur les signes de ponctuation, un étiqueteur morpho-syntaxique, des extracteurs de dépendances à courte et longue portée fondés sur des automates à états finis définis par des règles contextuelles.

#### **TagParser**

TagParser (Francopoulo, 2008) est un analyseur syntaxique pour le français et l'anglais. Une implémentation prototypique a été commencée en espagnol. La totalité du code a été écrit en Java de manière portable et industrielle sur une période de sept ans.

L'analyseur est de type montant. Il enchaîne les principaux modules suivants sous forme d'un pipeline : un segmenteur, un analyseur morphologique, un chunker et un module de calcul des relations syntaxiques. La sortie d'analyse comporte trois types de résultat : les constituants sans enchâssement, les relations syntaxiques et les entités

nommées. La communication d'un module à l'autre respecte les principes du LAF (*Linguistic Annotation Framework*), dans le sens où chaque module ajoute une annotation de type déportée (*stand-off* en anglais) sur la donnée transmise.

#### ShP1 et StP1

Les deux analyseurs ShP1 et StP1 (Vanrullen *et al.*, 2006) sont inclus dans une chaîne de traitement qui est composée d'un segmenteur par règles, et d'un lexique couvrant du français, qui alimentent l'entrée d'un étiqueteur morpho-syntaxique probabiliste. Ce sont deux analyseurs de surface, l'un symbolique et l'autre stochastique.

L'analyseur symbolique ShP1 est un analyseur déterministe. Il repose sur les Grammaire de Propriétés avec une stratégie de coin gauche. La grammaire utilisée est complète en ce sens qu'elle peut être utilisée indifféremment pour une analyse profonde ou superficielle. La particularité de ShP1 est de s'appuyer sur un sous-ensemble de contraintes de la grammaire (en particulier les propriétés de linéarité et de constituance) pour identifier les coins gauches. La stratégie consiste à repérer à partir des coins gauches la frontière droite du chunk sur la base des autres propriétés.

L'analyseur stochastique StP1, comme leur étiqueteur, est basé sur le modèle des patrons (Blache et Rauzy, 2006), un modèle de Markov caché plus performant que les modèles de type N-grammes.

#### Cordial

Cordial (CORrecteur D'Imprécisions et Analyseur Lexico-sémantique) (Laurent et al., 2009) est un analyseur syntaxique et sémantique développé par la société Synapse Développement. Il est conçu à l'origine pour la correction orthographique et grammaticale. Il associe à des règles générales et très peu liées aux attributs de genre et de nombre (analyseur à relâchement de contraintes) un ensemble d'outils statistiques, en particulier pour effectuer la désambiguïsation grammaticale.

Développé au début des années 90 mais constamment maintenu et enrichi depuis, Cordial est le fondement de nombreux développements : composants linguistiques de nettoyage automatique de texte, extracteur de mots-clés et de phrases-clés, extracteur de thèmes et de concepts, extracteur de terminologie et d'entités nommées, moteur de question-réponse. Conçu pour la langue française, Cordial est devenu bilingue, l'analyseur syntaxique et de nombreuses ressources ayant été progressivement adaptées pour la langue anglaise.

#### **SYGMART**

L'analyseur SYGFRAN (Béchet, 2009) est basé sur le système SYGMART (Système Grammatical de Manipulation Algorithmique et Récursive de Texte). C'est un système transformationnel prenant en entrée une chaîne de caractères et proposant en sortie une structure arborescente. Il se fonde sur les algorithmes de Markov, étendus aux arbres. Il permet d'analyser tout langage dont la grammaire pourrait être écrite sous forme de transducteurs d'arbres. L'analyseur SYGFRAN génère une analyse en constituants d'un

énoncé en français. Il est constitué de plus de 11 000 règles dans le but de produire une analyse morpho-syntaxique de la langue française.

#### **XIP**

L'analyseur XIP (Xerox Incremental Parsing) (Aït-Mokhtar et al., 2002) est développé par la société Xerox Research Center Europe. Il est basé sur un formalisme qui intègre un certain nombre de mécanismes de description d'analyse robuste profonde et peu profonde. Les grammaires XIP ont été développées pour un certain nombre de langues dont le français et l'anglais, et quelques autres sont en cours de développement en dehors de Xerox (japonais, chinois, allemand, tchèque). Les applications principales incluent la reconnaissance d'entités, la désambiguïsation lexicale et structurelle, la résolution de coréférence et plus globalement l'extraction de connaissances.

#### 2.2 Lexiques syntaxiques

Cette section évoque les lexiques syntaxiques en 2.2.1, puis détaille quelques lexiques du français en 2.2.2, avant de finir par une présentation rapide des principaux lexiques de l'anglais en 2.2.3.

#### 2.2.1 Introduction

Un lexique syntaxique est une ressource qui contient l'information sur le potentiel combinatoire d'un prédicat (par exemple, le verbe dormir régit un seul argument, le sujet), mais aussi sur le type de ses arguments (par exemple, l'adjectif fier se combine avec un syntagme prépositionnel en de). Ces informations varient d'une langue à l'autre, elles sont donc essentielles pour l'apprentissage et l'acquisition des langues. Pour le TAL, les informations sur la structure prédicative sont importantes dans la plupart des applications. Briscoe et Carroll (1993) estiment qu'environ la moitié des erreurs des analyseurs syntaxiques repose sur des informations insuffisantes concernant la structure argumentale, tandis que Carroll et Fang (2004) montrent une amélioration significative de la performance d'un analyseur syntaxique enrichi avec un tel lexique. Ces informations jouent également un rôle essentiel pour la génération automatique (Danlos, 1985), la traduction automatique (hye Han et al., 2000), ou l'extraction d'information (Surdeanu et al., 2003).

Néanmoins, ce type d'informations est toujours difficilement disponible. Traditionnellement, de telles ressources ont été développées par des experts humains, par exemple, le Lexique-Grammaire (Gross, 1975) et le DECFC (Dictionnaire explicatif et Combinatoire) de Mel'čuk et al. (1999), ce qui garantit leur bonne qualité, mais elles ne sont pas directement adaptées au traitement automatique. Par contre, les ressources informatisées développées automatiquement en vue des applications de TAL, par exemple Bourigault et Frérot (2005), utilisent des méthodes statistiques, ce qui rend les résultats moins fiables.

#### 2.2.2 Les lexiques syntaxiques du français

Plusieurs ressources lexicales syntaxiques pour le français ont été développées depuis de nombreuses années. Les objectifs de ces lexiques sont de définir, pour chaque lemme <sup>5</sup> donné pouvant être le noyau syntaxique d'une phrase, ses différents emplois et, pour chacun de ces emplois, son (ou ses) cadre(s) de sous-catégorisation spécifiant le nombre et le type de ses arguments, et les informations complémentaires qui s'y rapportent.

#### Les tables du Lexique-Grammaire

Les tables du Lexique-Grammaire constituent la plus ancienne ressource électronique pour le français. Cette ressource regroupe des informations sur la syntaxe des verbes, noms, adjectifs et adverbes dans un format électronique avec une description systématique (Gross, 1975). L'objectif de cette thèse est de la rendre directement exploitable dans un analyseur syntaxique. Elle contient 76 672 entrées correspondant à 62 128 lemmes distincts couvrant uniquement des prédicats. L'ensemble des tables est téléchargeable sous une licence libre (LGPL-LR) sur le site <a href="http://infolingu.univ-mlv.fr">http://infolingu.univ-mlv.fr</a> (Données Linguistiques > Lexique-Grammaire > Téléchargement).

Les tables du Lexique-Grammaire font l'objet du chapitre 3.

#### Lefff

Le Lefff (Lexique des Formes Fléchies du Français) est un lexique morphologique et syntaxique pour le français (Sagot et Danlos, 2007; Sagot, 2010). Au niveau morphologique, il contient 536 375 entrées correspondant à 110 477 lemmes distincts couvrant toutes les catégories. Au niveau syntaxique, 10 273 de ces entrées possèdent un cadre de sous-catégorisation. Il est téléchargeable sous une licence libre (LGPL-LR) sur le site http://gforge.inria.fr/projects/alexina/.

Le Lefff fait l'objet de la section 4.1.

#### **DICOVALENCE**

DICOVALENCE (van den Eynde et Mertens, 2006), successeur du lexique PROTON (van den Eynde et Mertens, 2003), est un dictionnaire syntaxique de verbes construit manuellement dans le cadre méthodologique de l'Approche Pronominale (Blanche-Benveniste et al., 1987). Il est téléchargeable sous une licence libre (LGPL-LR) sur le site http://bach.arts.kuleuven.be/dicovalence/. DICOVALENCE comporte les cadres de valence 6 de 8 313 entrées verbales, correspondant à 3 738 verbes distincts.

<sup>5.</sup> Le *lemme* est la forme canonique du mot, le plus souvent au masculin singulier. Il représente un ensemble de mots avec la même racine, la même catégorie lexicale et le même sens.

<sup>6.</sup> Par cadre de valence on entend traditionnellement le nombre et la nature des compléments valenciels du verbe, y compris le sujet, avec mention de leur fonction syntaxique.

Il s'agit de tous les verbes du Petit Robert, à l'exception de ceux appartenant à la terminologie technique et à des emplois archaïques.

Pour identifier la valence d'un prédicat (c'est-à-dire ses dépendants et leurs caractéristiques), l'Approche Pronominale exploite la relation qui existe entre les dépendants dits lexicalisés (réalisés sous forme de syntagmes) et les pronoms qui couvre en intention ces lexicalisations possibles. Les pronoms (et les paranoms, cf. ci-dessous), contrairement aux syntagmes, aux fonctions syntaxiques ou aux rôles thématiques, ont deux avantages majeurs :

- tout en étant des éléments de référence minimale, ils sont des éléments purement linguistiques, dénués des propriétés qui rendent difficile l'interprétation de la grammaticalité d'énoncés utilisant des dépendants syntagmatiques,
- ils sont en nombre restreint : leur inventaire est fini.

La valence peut donc être obtenue sans qu'il y ait besoin d'un travail d'interprétation, à l'aide d'une vérification systématique et exhaustive des combinaisons entre les différents pronoms et le prédicat verbal. Les pronoms retenus forment un ensemble plus large que ce qui est usuellement désignée par le terme de pronom : il s'agit des pronoms clitiques, des pronoms personnels pleins et des pronoms dits suspensifs (qui regroupent ce que l'on appelle habituellement pronoms interrogatifs et adverbes interrogatifs ou indéfinis, comme à qui, quand, etc.). Sont également pris en compte les paranoms, qui se distinguent des pronoms par leur modifiabilité (rien modifié dans rien d'intéressant) et l'impossibilité de reprise par un syntagme (\*il ne trouve rien, les indices<sup>7</sup> à comparer à il les trouve, les indices).

Les combinaisons entre prédicats et pronoms induisent des paradigmes de portée globale. Certains correspondent à peu près aux traditionnelles fonctions syntaxiques (P0 = je, tu, il, elle, qui, etc. correspond à la fonction sujet, P1 à la fonction objet direct, P2 à la fonction à-objet ou dative, etc.), d'autres permettent des distinctions plus fines que dans d'autres approches (PQ paradigme de quantité, PM paradigme de manière, etc.). DICOVALENCE proprement dit se présente comme une liste d'entrées correspondant chacune à un emploi d'un lemme verbal (il y a en moyenne 2,4 entrées par lemme). Sont tout d'abord donnés l'entrée et son type : prédicateur simple, verbe adjoint, verbe auxiliaire, verbe copule, verbe de dispositif, construction résultative (van den Eynde et Mertens, 2006). Suivent alors les différents paradigmes qui dépendent du prédicateur (les termes de valences), avec pour chacun d'eux la liste des pronoms et paranoms qui peuvent en être la réalisation. Sont enfin indiquées certaines propriétés complémentaires, dont les passivations possibles (passif être, se passif et/ou se faire passif).

#### Les Verbes Français

Les Verbes Français (LVF) est un dictionnaire syntaxico-sémantique de verbes construit manuellement par Dubois et Dubois-Charlier (1997) qui est téléchargeable sous une licence libre (LGPL-LR) sur le site du laboratoire MoDyCo (CNRS & Université

<sup>7.</sup> Un exemple précédé du signe \* désigne une phrase non acceptable (ou éventuellement acceptable dans un emploi différent de celui qui est envisagé).

Paris 10) <sup>8</sup>. À chaque verbe est associé une classe syntaxico-sémantique, c'est-à-dire une classe sémantique définie par la syntaxe. Au total, LVF compte 25 610 entrées verbales, correspondant à 12 310 verbes distincts. Un tiers d'entre eux font l'objet de plusieurs entrées. Il y a 290 verbes qui ont 10 entrées ou plus. Exemple d'un cas extrême : le verbe passer comporte 61 entrées.

Pour l'élaborer, les auteurs ont utilisé «les méthodes classiques de la grammaire distributionnelle et transformationnelle» (Dubois et Dubois-Charlier, 1997) (p. III). De fait, les principes de LVF sont proches de ceux du Lexique-Grammaire et il s'inscrit dans la tradition des grammaires de Z. Harris. Pour chaque entrée, une seule construction syntaxique est associée, précisant le nombre et la nature (en particulier prépositionnelle) du sujet et des compléments.

#### **Autres**

Nous pouvons également mentionner d'autres ressources telles que :

- LexValf (Lexique des Valences verbales du Français) (Salkoff et Valli, 2005), qui se consacre à la description de particularités syntaxiques de constructions des unités lexicales verbales. Son objectif est de mettre en commun manuellement diverses données telles que les tables du Lexique-Grammaire, LVF, le Web attesté et de grands dictionnaires de langue française tels que le Grand Robert, le Petit Robert et le Trésor de la Langue Française. Il contient 975 verbes parmi les plus fréquemment utilisés du français;
- DiCo (Dictionnaire Combinatoire) (Mel'čuk et Polguère, 2006), qui est basé sur les mêmes principes que le DECFC de Mel'čuk et al. (1999) et représente une modélisation des liens lexicaux du français. Sa finalité première est de décrire chaque entrée selon deux axes : les dérivations sémantiques (relations sémantiques fortes) qui la lient à d'autres entrées de la langue et les collocations (expressions semi-idiomatiques) qu'elle contrôle. Ce dictionnaire inclut 1 075 entrées et 25 540 liens lexicaux;
- VfrLPL, qui fait partie de DicoLPL (Dictionnaire du Laboratoire Parole et Langage) (Vanrullen et al., 2005). C'est un lexique syntaxique des verbes du français qui contient 8 800 entrées verbales correspondant à 6 700 verbes distincts. Il décrit pour chaque entrée ses traits morphologiques, sa forme phonétisée, sa fréquence et le lemme sous-jacent. Les verbes contiennent quelques informations concernant la sous-catégorisation. DicoLPL a été constitué sur la base d'un lexique interne au Laboratoire Parole et Langage, puis complété par croisement de ressources existantes et vérification sur corpus.

Une autre ressource publique de grande ampleur est le **TLFi** (Trésor de la Langue Française Informatisé) (Dendien et Pierrel, 2003), développé par le laboratoire ATILF. Ce dictionnaire, bien que très structuré, a été d'abord conçu comme un dictionnaire grand public (pour consultation humaine). Il ne peut donc constituer en l'état une composante d'un modèle linguistique du français. On peut néanmoins en extraire, automati-

<sup>8.</sup> Lien vers le site de diffusion sur le site FondamenTAL : http://www.lif.univ-mrs.fr/IMG/html/FondamenTAL.html

quement ou semi-automatiquement, une grande quantité d'informations précieuses pour l'élaboration d'un modèle formel.

Des ressources lexicales ont également été acquises semi-automatiquement. C'est le cas notamment de **TreeLex** (Kupść, 2007), acquis automatiquement à partir du corpus arboré de Paris 7 (Abeillé, 2003), avec environ 2 000 lemmes verbaux.

Ou encore automatiquement à partir de corpus bruts, comme **LexSchem** (Messiant, 2010), qui a été acquis à partir du corpus journalistique LM10, constitué des articles de 10 années (1991-2000) du journal *Le Monde*. Il contient 7 239 verbes associés à un cadre de sous-catégorisation, dont 3 123 lemmes verbaux différents. De plus, la complémentarité de l'approche probabiliste et symbolique a été étudiée par (Messiant *et al.*, 2009), en comparant LexSchem (lexique acquis par des méthodes automatiques) avec les tables du Lexique-Grammaire (lexique construit manuellement). Ils montrent que les informations acquises par ces deux méthodes sont bien distinctes et qu'elles peuvent s'enrichir mutuellement.

#### 2.2.3 Les lexiques syntaxiques de l'anglais

VerbNet (Kipper et al., 2000) est un lexique des classes de verbes de l'anglais. C'est un projet mené sous l'impulsion de M. Palmer (à l'université de Pennsylvanie, puis à l'université du Colorado). VerbNet regroupe par classe les verbes partageant les mêmes comportements syntaxiques et sémantiques. C'est un prolongement des travaux de Levin (1993).

Une classe de verbes regroupe plusieurs verbes, et identifie des rôles thématiques avec d'éventuelles contraintes de sélection. Elle décrit plusieurs constructions typiques (des frames) des verbes membres. La sémantique de l'action ou de l'événement est également précisée. Des sous-classes permettent de décrire d'éventuelles spécialisations d'une classe. On peut en trouver une description dans Kipper-Schuler (2003).

La version la plus récente (VerbNet 3.1), datant de 2009, distingue 270 classes de verbes qui regroupent 5 879 sens de verbes.

ComLex Syntax (Grishman et al., 1994) est un lexique syntaxique à large couverture pour l'anglais, développé par Proteus Project à l'université de New York. La première version de ComLex Syntax a été diffusée par le Linguistic Data Consortium (LDC) en 1994 et la version finale en 1997. Le lexique inclut les entrées de 21 000 noms, 8 000 adjectifs et 6 000 verbes. Les noms ont 9 traits syntaxiques et 9 compléments possibles, les adjectifs ont 7 traits syntaxiques et 14 compléments, les verbes ont 5 traits syntaxiques et 92 compléments et les adverbes ont 11 positions et 12 traits syntaxiques. Pour les 750 verbes plus fréquents, il y a de plus 4 traits syntaxiques et 32 compléments possibles.

NomLex (Nominalization Lexicon) (Macleod et al., 1997) est un lexique sur les nominalisations de verbes de l'anglais développé également par Proteus Project à l'université de New York, sous la direction de C. Macleod. NomLex cherche non seulement à décrire les arguments syntaxiques associés aux noms prédicatifs, mais aussi à les relier aux arguments du verbe dont ils dérivent, décrit dans ComLex Syntax. Le lexique compte 1 025 entrées de plusieurs types de nominalisations lexicales, incluant

plus de 1 000 mots distincts. La première version de NomLex a été publiée en 1999 et la dernière version, librement disponible, date de 2001.

FrameNet (Baker et al., 1998), projet mené à Berkeley à l'initiative de C. Fillmore, est de créer une ressource lexicale pour l'anglais fondée sur la sémantique des cadres (frame semantics) et confirmée par des attestations dans des corpus. FrameNet a pour objectif de documenter la combinatoire syntaxique et sémantique (ou valence) pour chacun des sens d'une entrée lexicale à travers une annotation manuelle d'exemples choisis dans des corpus sur des critères de représentativité lexicographique. Les annotations sont ensuite synthétisées dans des tables, qui résument pour chaque mot les cadres avec leurs actants sémantiques et arguments syntaxiques. Les fonctions grammaticales reconnues sont sujet, objet et une troisième catégorie pour les compléments obligatoires et les modifieurs, sans les distinguer.

FrameNet 1.5 compte actuellement 960 cadres sémantiques, 11 600 unités lexicales (dont 6 800 complètement annotées) ainsi que 150 000 phrases d'exemples annotés. La totalité des outils et des données est distribuée librement.

Chapitre 2 Les analyseurs syntaxiques et les lexiques syntaxiques

### Les tables du Lexique-Grammaire

Dans la section 3.2 nous présentons les motivations initiales de la création des tables du Lexique-Grammaire. Des exemples de tables sont donnés et l'ensemble des notations utilisées sont décrites dans la section 3.1. Les tables constituent le point de départ de notre travail.

#### 3.1 Notations du Lexique-Grammaire

De manière générale, les notations utilisées sont celles de Gross (1986b):

 Les constructions syntaxiques sont représentées par des suites de symboles telles que :

#### N0 V N1 Prép N2

dénotant une suite «sujet - verbe - objet direct - complément prépositionnel» comme par exemple dans la phrase *Paul débat cette question avec Luc*.

N désigne un argument syntaxique, c'est-à-dire le sujet ou un complément essentiel. Les chiffres à droite des N indiquent leur placement de gauche à droite dans la construction de base :

- N0 : sujet;
- N1 : premier complément ;
- N2 : deuxième complément, etc.

La notation Ni est utilisée pour désigner le sujet à l'intérieur d'une complétive, comme dans Qu Psubj =: Qu Ni Vsubj W = (Ni) (de Vi-inf W), qui indique qu'une complétive au subjonctif introduite par que et de la forme Ni Vsubj W peut être remplacée par un constituant Ni suivi d'une infinitive Vi-inf W, introduite par la préposition de (Paul empêche que Pierre vienne = Paul empêche Pierre de venir). Les chiffres à droite des autres symboles, tels que Adj, Det, Prép, Loc, C, etc. in-

diquent ce même placement. Par exemple, Prép1 désigne la préposition du premier complément, même si la préposition peut ne pas être numérotée dans les constructions, comme c'est le cas pour les verbes (par exemple, dans N0 V Prép N1). De plus, cette numérotation peut être utilisée pour faire référence à un argument syntaxique de la phrase. Par exemple, le pronom lui-même peut être noté lui1-même, ce qui indique que le pronom lui est coréférent à l'objet N1 (Le froid a recroquevillé la plante sur elle-même).

N peut également représenter un substantif ou un groupe nominal lorsqu'un trait sémantique apparaît à droite du N, ou du chiffre (sauf Nnr qui peut désigner une complétive ou une infinitive). Dans la mesure où l'on se focalise très peu sur les déterminants, les adjectifs et les relatives, cette ambiguïté, loin de présenter des inconvénients, permet de représenter simultanément tout un groupe nominal, ainsi que le substantif tête de ce groupe nominal.

Voici quelques exemples de traits sémantiques figurant dans les constructions :

- N0hum: sujet pris dans la classe des substantifs humains (par exemple, (L'ennemi+Luc) quitte la ville);
- N1pl obl : premier complément obligatoirement au pluriel (par exemple, La bouteille a éclaté en mille morceaux);
- N2pc : deuxième complément pris dans la classe des substantifs parties du corps (par exemple, Paul joint le pouce avec l'index).

Ces mêmes traits sémantiques peuvent faire l'objet à eux seuls d'une propriété distributionnelle écrite sous la forme N0 =: Nhum, N1 =: Npl obl ou N2 =: Npc. Pour cette dernière, on peut indiquer la coréférence avec un substantif de la même phrase en ajoutant un chiffre à droite du trait sémantique pc. Par exemple, C1 =: Npc0 (C1 désignant le substantif tête du premier complément figé dans une expression figée) est employé pour C1pc de N0, c'est-à-dire C1pc portant obligatoirement sur N0 (par exemple,  $Max\ a\ la\ tête\ ailleurs$ );

– Les parenthèses contenant plusieurs éléments séparés par le signe + indiquent un choix possible entre ceux-ci ; la lettre E désigne l'élément vide. Ainsi :

N0 V (E+N1): Jean lit (E+un livre) correspond aux deux structures:

 $N0 \ V: Jean \ lit$ 

NO V N1: Jean lit un livre;

- Un signe + entourant deux chiffres sans parenthèses désigne les arguments concernés, comme par exemple dans N0 V N1 + 2, qui représente une phrase avec un objet direct interprété par métonymie comme les deux objets (Léa a boutonné un pan de sa robe avec l'autre = Léa a boutonné sa robe);
- Les parenthèses ne contenant pas de signe + permettent de délimiter un argument,
   comme par exemple dans N0 V (N1 de N1c) = N0 V (N1c) (Prép N1) (Luc stimule la curiosité de Marie = Luc stimule Marie dans sa curiosité);
- Les deux notations =: et = se différencient par le fait que la première signifie «se spécifie ou se développe en» : elle précise une distribution possible d'un ou plusieurs éléments d'une construction ; alors que le = signifie «est transformationnellement lié à» : il suppose toujours l'existence d'une nouvelle construction (représentée à

droite du signe) par rapport à une déjà connue (représentée à gauche). Par exemple, à N1 = Ppv =: le signifie que l'argument à N1 peut être pronominalisé en le (Paul apprend à lire = Paul l'apprend);

- Les crochets représentent une transformation, telle que [extrap] pour l'extraposition,
   ou [passif par] (respectivement, [passif de]) pour le passif introduit par la préposition
   par (respectivement, de);
- La notation => désigne une implication, telle que dans impératif => subj, qui implique que la complétive soit au subjonctif lorsque la phrase exprime un ordre (Max ordonne que Paul vienne), ou (Nég, interro) => subj, où la négation ou l'interrogation peuvent entraîner la mise au subjonctif de la subordonnée (Je crois qu'il viendra / Je ne crois pas qu'il vienne / Crois-tu qu'il vienne?);
- La notation # signifie «différent de», par exemple Loc # de désigne une préposition locative différente de de;
- La notation 'P' désigne un discours direct, comme dans N0 V à N2 : 'P', où c'est la complétive N1 qui peut prendre la forme d'un discours direct (Luc répond à Léa qu'il va au cinéma = Paul répond à Marie : «Je vais au cinéma»), ou 'P', V N0 à N2, où de plus, elle apparaît en tête de phrase («Je vais au cinéma», répond Luc à Léa);
- La notation <ENT> représente tous les mots faisant partie de l'entrée et la notation
   <OPT>, ceux faisant partie d'entrées associées <sup>1</sup>.

Traditionnellement (Gross, 1986b), les chiffres sont soit en indice pour numéroter les arguments syntaxiques, soit en exposant pour noter la coréférence, ce qui facilite l'interprétation des intitulés. Par exemple, la construction  $N0 \ V \ Loc \ N1 \ V0$ -inf W est notée  $N_0 \ V \ Loc \ N_1 \ V^0$ -inf W. Nous n'avons pas retenu cette distinction dans les intitulés de propriétés des tables, car il n'existe aucun cas où la distinction entre deux intitulés repose uniquement sur la distinction indice/exposant. De plus, l'interprétation des intitulés repose maintenant sur une documentation précise (voir 5.3.3).

#### Les symboles utilisés sont :

- Adj : Adjectif; peut être suivi de permut obl pour indiquer que l'adjectif doit être obligatoirement permuté avec le nom;
- Adj-ment : Adverbe dérivé d'un adjectif, auguel on a ajouté -ment;
- Adj-n : Nom morphologiquement associé à un adjectif;
- Adv: Adverbe; le rôle sémantique de l'adverbe peut être spécifié: Advm pour adverbe de manière, Advp pour adverbe de prix, AdvI pour adverbe de lieu, Advt pour adverbe de temps, Advfut pour adverbe de temps futur, Advtd pour adverbe de temps duratif, etc.;
- AdvPhrase : Adverbe de phrase ;
- autre suivi d'un autre symbole (par exemple, Loc1) : Autres valeurs lexicales possibles de ce symbole, en plus de celles représentées dans les propriétés binaires;
- Aux : Auxiliaire ;
- C: Substantif figé inclus dans la structure d'un argument figé tel que par exemple,

<sup>1.</sup> Pour les tables verbales, cette notation est employée pour désigner la colonne contenant l'exemple. De plus, <ENGLISH> représente la traduction du verbe en anglais.

- Det1 C1 Adj1 dans la construction N0 faire Det1 C1 Adj1 à N2, à contraster avec les arguments libres, ici N0 et N2;
- combien? : Complément précisant une quantité ou une mesure intéressant le procès, et souvent à déterminant numéral;
- Conj : Conjonction ; la nature de la conjonction peut être spécifiée : ConjC pour conjonction de coordination et ConjS pour conjonction de subordination ;
- Det : Déterminant (simple ou accompagné d'un modifieur, par exemple un certain);
   la nature du déterminant peut être spécifiée : Det1 =: déf pour déterminant défini,
   Det1 = : indéf pour déterminant indéfini, Dnum pour un déterminant numéral;
- Det N : Déterminant et prédicat nominal ;
- Detc : Déterminant du complément de nom Nc;
- dé-V : Verbe dérivé de V par un préfixe négatif;
- du: Article partitif  $(du+de \ la)$ ;
- E ou <E> : Absence ou effacement d'un élément; représente l'élément neutre de la concaténation et sert à marquer la séquence vide (préposition zéro, déterminant zéro, etc.);
- GN: Groupe nominal;
- le : Article défini (le+la+l');
- Loc : Préposition locative, c'est-à-dire introduisant un complément de lieu (dans, sur, à, etc.);
- Modif: Tout modifieur (relative, adjectif, complément de nom, épithète, etc.) d'un groupe nominal; un déterminant suivi d'un modifieur (avec la notation Det-Modif) représente un constituant discontinu formé par le déterminant et le modifieur obligatoire;
- N : Substantif ou groupe nominal, ou argument syntaxique (sujet ou complément essentiel), comme détaillé au paragraphe précédent;
  - traits sémantiques possibles (attachés au N): hum (entité humaine)<sup>2</sup>, -hum (entité qui n'est pas une personne ni un animal linguistiquement assimilé à une personne), pc (partie du corps d'une personne), pc obl (obligatoirement une partie du corps, ou, par métonymie, une personne), plur (pluriel), pl obl (pluriel obligatoire ou collectif), abs (entité abstraite), conc (objet concret), nr (substantif dénotant une personne, un objet concret, une entité abstraite, une complétive ou une infinitive), pr (nom propre), monnaie (nom de monnaie, une somme d'argent), mes (nom d'unité de mesure), esprit (esprit d'une personne), idée, texte, mot, chemin (situation statique dans laquelle une personne ou une chose peut effectuer un trajet sur ce chemin), coup, trou, couche (couche d'une substance concrète), zone, transport (moyen de transport), instrument, point, trace (trace ou marque), déformation, mal (maladie), psy (psychologique), nc (non contraint);
  - rôles thématiques possibles (séparés de N par un espace) : lieu source (lieu source du référent d'un autre argument), lieu de destination (lieu de destination du référent d'un autre argument), nv-dest (nouvelle destination), mouvement (objet

<sup>2.</sup> La notation  $\mathsf{hum}$  obl (obligatoirement entité humaine) a été supprimée comme nous le verrons en 6.2.2.

ou lieu en mouvement), lieu du passage (lieu par lequel passe le référent du sujet), lieu du procès (lieu où se déroule le procès), apparition (apparaissant ou étant créé au cours du procès), disparition (disparaissant au cours du procès), bénéficiaire (bénéficiaire du référent d'un autre argument), détrimentaire (détrimentaire du référent d'un autre argument), matériau (matériau utilisé dans le procès), attache (système d'attache interprété comme un instrument), résultat, actif (personne interprétée comme active), neutre (la phrase dénote un événement datable), statique (la phrase dénote une situation statique), métaphore (la phrase a un sens métaphorique), scénique (locatif);

- Nc : Complément de nom ;
- Neg : Adverbe de négation, ou pronom clitique ne figé avec le verbe V dans Ppv =: Neg;
- P: Phrase ou proposition;
- Ppv : Pronom clitique ou particule préverbale (me+m'+te+t'+se+s'+le+la+l'+les+lui+nous+vous+leur+en+y); il peut être obligatoirement figé avec le verbe V si figé est mentionné, comme par exemple dans Ppv =: en figé;
- Poss : Déterminant possessif (mon+ton+son+ma+ta+sa+mes+tes+ses+notre +votre+leur+nos+vos+leurs); un chiffre peut indiquer à quel argument le déterminant possessif est coréférent, par exemple Poss0 est coréférent au sujet N0;
- Prép : Préposition ; Prép-adv désigne sa modification sous une forme adverbiale ;
- Qu P : Complétive sans distinction de contenu, introduite par le pronom que; le mode de la complétive peut être spécifié : Qu Pind pour une complétive à l'indicatif et Qu Psubj pour une complétive au subjonctif; le ce de la complétive peut être indiqué, mais également la locution du type le fait que introduisant la complétive notée le fait Qu P;
- Tc : Temps (éventuellement de l'adverbe) faisant partie de l'infinitive;
- thèmeN1: Exemple prototypique de nom qui peut occuper la position de l'objet N1;
- tout : Déterminant indéfini dérivé de tout (tout+tous+toute+toutes);
- Tp: Temps (éventuellement de l'adverbe) faisant partie de la principale;
- trajet : Complément locatif introduit par la préposition sur ou le long de et interprété comme un lieu de passage;
- un : Article indéfini (un+une);
- V : Verbe, défini morphologiquement ;
- V-able, V-ateur, V-eur, ou V-eux : Adjectif déverbal lié à V avec un suffixe -able, -ateur, -eur, ou -eux;
- V-adj : Adjectif déverbal lié à V;
- V-ant : Adjectif déverbal lié à V avec un suffixe -ant ou -ent (par exemple, dans N0 être V-ant : Paul sourit = Paul est souriant), ou verbe au participe présent dans N1 = (N) (V-ant W) (J'ai repéré que Paul travaille = J'ai repéré Paul travaillant);
- V-inf W : Verbe à l'infinitif, suivi de toute suite de compléments, y compris vide ; le sujet des infinitives peut être spécifié par un chiffre, par exemple :

N0 V V0-inf W: Jean veut manger cela

V1-inf W V N1: Venir ici ennuie Marie

V2-inf W V N1 à N2 : Faire ceci donne du mal à Paul

Le sujet peut également être coréférent à un complément de nom de l'objet N1 par exemple et noté N0 =: V1c-inf W : Se présenter aux élections a germé dans la tête de Paul

Ou encore être coréférent avec le sujet de la complétive objet N1 et noté N0 =: Vi-inf W : Être trop gros empêche Luc de passer dans le couloir ;

- V-n : Substantif de la même famille morphologique que V, -n étant un suffixe nominalisateur; parfois le suffixe, noté Sfx, est précisé, par exemple dans Sfx = -ment;
- Vc : Verbe faisant partie de l'infinitive;
- Vconv : Verbe support converse ;
- Vop : Verbe opérateur, généralement causatif; la phrase Paul fait boire Marie est analysé par application de l'opérateur Paul fait à la phrase Marie boit;
- Vsup : Verbe support ;
- Vpp : Verbe au participe passé;
- W : Suite quelconque, éventuellement nulle, de compléments; cette notation peut indiquer la conservation des autres compléments éventuels dans une construction.

Les autres symboles sont des valeurs lexicales de verbes, prépositions, pronoms, conjonctions, adverbes ou modifieurs.

#### 3.2 Point de départ : Les tables du Lexique-Grammaire

Une part importante des travaux en syntaxe, se concentre sur l'identification et la formalisation de règles générales s'appliquant à une classe étendue de mots. Précisément, les règles de transformation de Chomsky décrivent des relations systématiques entre les diverses structures syntaxiques.

Mais, comme Chomsky (1965) lui-même le remarquait, ces généralisations ont souvent de fortes contraintes lexicales. Pour chaque mot, la question se pose de savoir si une généralisation donnée s'applique à ce mot. En d'autres termes, la description complète de la syntaxe d'une langue implique non seulement l'identification de règles générales, mais également la détermination de quel mot exige, autorise ou interdit, l'application de quelle règle en particulier. Ce fut l'orientation des recherches effectuées par Gross (1975).

Ce dernier constate l'absence d'exhausitivité dans la plupart des démarches, qui se basent uniquement sur quelques exemples choisis sans se soucier de tester la validité de leurs règles ou hypothèses. Comme l'énonce M. Gross, il faut étudier une langue selon les principes élémentaires suivants :

- les expériences doivent porter sur des quantités de données significatives;
- elles doivent être reproductibles;
- les exceptions aux règles doivent être recensées;
- les modifications du cadre formel doivent être très soigneusement justifiées et demeurer extrêmement rares.

L'objectif étant d'accumuler des données empiriques aussi complètes et détaillées que possible, c'est ce qui a donné naissance à une grande base de données lexicales, syntaxiques et sémantiques : les tables du Lexique-Grammaire.

M. Gross prend comme point de départ l'étude des phrases simples du français. Il reprend ainsi l'idée selon laquelle l'unité minimale de sens est la phrase. Le principe qu'il adopte est donc de répertorier les phrases simples et d'étudier les transformations qu'elles peuvent subir. Les propriétés étudiées pour chacune de ces phrases sont essentiellement des propriétés formelles portant sur la syntaxe plutôt que sur la sémantique, ce qui garantit la reproductivité des tests (Gross, 1975). Toutefois, certaines propriétés sémantiques ont été prises en compte lorsqu'elles pouvaient être testées de façon claire.

Les tables du Lexique-Grammaire du français sont les plus développées, mais des descriptions dans d'autres langues telles que l'italien, le portugais, le grec moderne, et des langues non européennes (coréen, malgache, etc.) sont également disponibles.

Leur développement a été initié dès les années 1970 par Gross (1975), au sein du Laboratoire d'Automatique Documentaire et Linguistique (LADL), puis du Laboratoire d'Informatique Gaspard-Monge (LIGM) de l'Université Paris-Est (Boons et al., 1976a,b; Guillet et Leclère, 1992). Ces informations se présentent sous la forme de tables. Chaque table correspond à une classe qui regroupe les éléments lexicaux d'une catégorie lexicale donnée (verbes, noms, adjectifs, etc.), partageant certaines propriétés syntaxico-sémantiques.

Chaque classe correspond à une ou plusieurs constructions syntaxiques particulières, et rassemble toutes les entrées qui entrent dans cette ou ces constructions. Par exemple, la table 1 des verbes distributionnels contient tous les verbes qui admettent, en plus d'un sujet, un complément infinitif, mais pas un complément qui soit une complétive (par exemple, le verbe *commencer* dans *Luc commence* à *lire*).

Une table se présente sous forme de matrice : en lignes, les entrées lexicales de la classe correspondante; en colonnes, les propriétés syntaxico-sémantiques, qui ne sont pas forcément respectées par tous les éléments de la classe; à la croisée d'une ligne et d'une colonne le signe + ou – indiquant que l'entrée lexicale décrite par la ligne accepte, ou n'accepte pas la propriété décrite par la colonne.

Une propriété syntaxico-sémantique est soit une information qui concerne directement la construction de base associée à la table, soit une transformation de la construction de base, soit une construction supplémentaire (par exemple, les constructions métaphoriques, qui n'ont pas les mêmes distributions d'arguments).

Par exemple, la propriété N0 V signifie pour un verbe «possibilité d'être la tête d'une construction intransitive avec le syntagme nominal sujet initial»; la propriété [passif par] signifie «diathèse passive possible».

À titre d'illustration, la Fig. 3.1 montre un extrait de la table 33 des verbes distributionnels  $^3$  qui se construisent avec un argument introduit par la préposition  $\grave{a}$ . Cela signifie qu'elle est composée des verbes ayant la propriété N0 V  $\grave{a}$  N1 vraie.

Si un verbe a deux sens distincts, il possède deux entrées lexicales puisque chaque sens n'accepte pas le même ensemble de propriétés. Un des exemples qui figure dans la

<sup>3.</sup> Les notations utilisées dans les intitulés sont détaillés dans la section 3.1.

| N0 =: Nhum  | N0 =: N-hum | NO =: Nnr | <ent>Ppv</ent>      | Ppv ≕ se figé    | Ppv =: les figé | =: Neg | <ent>V</ent>            | Neg              | No V      | NO être V-ant    | N0 V de N0pc     | N1 =: Nhum | N1 =: N-hum           | N1 =: le fait Qu P | Ppv =: lui       | Ppv =: y              | [extrap]         | N0idée V Loc N1esprit | <opt></opt>   |
|-------------|-------------|-----------|---------------------|------------------|-----------------|--------|-------------------------|------------------|-----------|------------------|------------------|------------|-----------------------|--------------------|------------------|-----------------------|------------------|-----------------------|---|
|             |             |           |                     |                  | - 1             |        | ' '                     |                  |           | - 1              |                  |            | - 1                   |                    |                  |                       |                  |                       |   |
| +           | _           | -         | les                 | _                | +               | _      | lâcher Advm             | _                | +         | _                |                  | +          | =                     | _                  | -                | -                     | -                | -                     | Max les lâche difficilement à Ida                                   |
| +           | _           | _<br>_    | les<br>  <e></e>    | _<br>_           | +               |        | lâcher Advm<br>renaître | _                | +         | _<br>+           | _                | +          | <b>-</b>              | -                  | _                | <b>-</b>              | -                | -<br>+                | Max les lâche difficilement à Ida<br>Max renaît au bonheur de vivre |
| + + +       |             | _<br>     |                     | _<br>_<br>+      | +               |        |                         | _<br>_<br>_      | + + +     | +                | -                | + - +      | -<br>+<br>+           | -<br>-<br>+        | _<br><br>        | -<br>+<br>+           | _<br>_<br>+      | _                     | •••   |
| + + + +     |             | _<br><br> | $\langle E \rangle$ | -<br>+<br>+      | +               |        | $rena \hat{\imath} tre$ | _<br>_<br>_      | + + + +   | -<br>+<br>-      | _<br>_<br>_      | + + + +    | -<br>+<br>+           | -<br>+<br>-        | _<br>_<br>_      | -<br>+<br>+           | -<br>-<br>+<br>- | +                     | Max renaît au bonheur de vivre<br>Max s'est rendu à mon opinion     |
| + + + + + + |             | -         | <e></e>             | -<br>-<br>+<br>+ | +               |        | renaître<br>rendre      | _<br>_<br>_<br>_ | + + + + - | -<br>+<br>-<br>- | _<br>_<br>_<br>_ | + + + + +  | -<br>+<br>+<br>-<br>+ | -<br>+<br>-        | _<br>_<br>_<br>_ | -<br>+<br>+<br>-<br>+ | -<br>-<br>+<br>- | +                     | Max renaît au bonheur de vivre                                      |

Table 3.1: Extrait de la table 33 des verbes distributionnels

table 33 est le verbe se rendre : Le caporal s'est rendu à l'ennemi Max s'est rendu à mon opinion

On peut voir que se rendre (dans le sens d'accepter) possède un complément nominal non humain : la propriété N1 =: N-hum est vraie (codage +), alors qu'elle est fausse (codage -) pour se rendre (dans le sens de capituler).

Il y a aussi des propriétés dont les valeurs sont des éléments lexicaux. Un extrait de la documentation (voir annexe E) de ces propriétés est présenté dans la Tab. 3.2. Ainsi, les compléments prépositionnels peuvent nécessiter différentes prépositions qui dépendent du prédicat. Dans la table 1 à la Fig. 3.3, les verbes sont suivis d'une préposition et d'une infinitive (ils acceptent donc la propriété N0 V Prép V0-inf W) : achever nécessite la préposition de, s'avancer nécessite la préposition de et de en nécessite pas de préposition, ce qui est symbolisé par le symbole de0.

Remarquons que le clitique s' figé avec le verbe avancer (s'avancer) est contenu dans la colonne <ENT>Ppv, tout comme le pronom obligatoire les du verbe lâcher, ou encore le clitique ne (marquant la négation) figé avec le verbe revenir. Pour simplifier le traitement informatique, nous avons créé les colonnes Ppv =: se figé, Ppv =: les figé, Ppv =: Neg, etc. avec un codage binaire, codage qui doit concorder avec les informations contenues dans la colonne <ENT>Ppv, laquelle n'est gardée que pour des raisons de lisibilité. Dans la colonne <ENT>V figure l'entrée verbale, avec y compris éventuellement un adverbe figé avec le verbe. On peut avoir, par exemple, Advm, Advt, etc., comme pour lâcher Advm, qui oblige la présence d'un adverbe de manière, comme dans Max les lâche difficilement à Ida; ou encore pas, plus, etc., ce qui contraint l'adverbe négatif. Si un adverbe négatif est obligatoirement présent dans la construction, mais a une valeur lexicale libre (pas, point, nullement, aucunement, aucun, nul, personne, rien, quère, jamais, plus, nulle part), il n'est plus inclus dans l'entrée verbale. En effet, la notation Nég correspondant à une valeur lexicale libre a été supprimée de l'entrée et fait à présent l'objet d'une nouvelle colonne binaire intitulée Neg, indiquant la présence obligatoire d'un adverbe de négation, y compris si l'adverbe est contraint et spécifié

| Propriétés      | Description de la propriété   |
|-----------------|---|
| <ent>V</ent>    | Forme de l'entrée verbale V. Si un adverbe est figé avec le verbe, il fait                        |
|                 | partie de la forme. Si des clitiques sont figés avec le verbe, ils ne font pas                    |
|                 | partie de la forme. Si un adverbe négatif est obligatoirement présent dans                        |
|                 | la construction, mais a une valeur lexicale libre (pas, point, nullement,                         |
|                 | aucunement, aucun, nul, personne, rien, guère, jamais, plus, nulle part),                         |
|                 | il ne fait pas partie de la forme   |
| (lexicale)      | Exemple : Ce film dure longtemps : durer Advt ; Luc n'arrête pas d'être                           |
|                 | dérangé : arrêter pas ; Votre geste ne va pas : aller   |
| <opt></opt>     | Phrase d'exemple illustrant le sens de l'entrée verbale V   |
| (lexicale)      | Exemple : Max achève de peindre le mur; Max achève les blessés                                    |
| <ent>Ppv</ent>  | Clitiques figés avec le verbe V. Les informations données dans cette pro-                         |
|                 | priété doivent concorder avec celles données dans les propriétés binaires                         |
|                 | intitulées Ppv =: en figé, etc.   |
| (lexicale)      | Exemple : Luc n'en revient pas de ce culot ; Luc se réserve pour la nuit                          |
| Ppv =: en figé  | Le pronom clitique $en/la/le/les/se/y$ est figé avec le verbe $V$                                 |
| (binaire)       | Exemple : Je n'en reviens pas de ce culot ; Luc s'en va   |
| Ppv =: la figé  | Fermez-la   |
| Ppv =: le figé  | La haine le dispute à la colère   |
| Ppv =: les figé | On va les aligner   |
| Ppv =: se figé  | Luc se réserve pour la nuit; Luc s'en va  |
| Ppv =: y figé   | Luc y va; Luc s'y croit   |
| Ppv =: Neg      | Le pronom clitique ne est figé avec le verbe V, même en l'absence d'un                            |
|                 | adverbe de négation   |
| (binaire)       | Exemple : Luc n'arrête pas d'être dérangé ; Luc ne saurait dormir ici                             |
| Neg             | Présence obligatoire d'un adverbe de négation   |
| (binaire)       | Exemple : Luc n'arrête pas d'être dérangé   |
| Prép1           | Prépositions de l'objet N1/N2/N3  |
| (lexicale)      | Exemple: Max va jusqu'à exiger des dommages: jusqu'à; Le verre va                                 |
|                 | $tomber: \langle \mathbf{E} \rangle$ ; Qu'Ida est idiote éclate aux yeux de tous : $\mathbf{Loc}$ |
| Prép2           | Max a accrédité auprès des parents la nouvelle que Luc est mort : auprès                          |
|                 | de ; Max a encadré dans ce texte que Luc était absent : Loc ; Max a pour                          |
|                 | preuve de cela qu'il ne s'est pas montré : pour+comme   |
| Prép3           | Max désigne Luc à Léa pour faire ce travail : pour ; Max a reçu de Luc                            |
|                 | $comme\ garantie\ qu'il\ aurait\ une\ prime\ : <$ E $>$   |
| autre Loc1      | Prépositions de l'objet locatif Loc N1 autres que celles représentées dans                        |
|                 | les propriétés binaires intitulées Loc $N1 =: a N1$ , etc.  |
| (lexicale)      | Exemple : Les convives farandolent autour de la table ; Les délinquants                           |
|                 | se recrutent (parmi+chez) les riches  |
| autre Loc2      | Prépositions de l'objet locatif Loc N2 autres que celles représentées dans                        |
|                 | les propriétés binaires intitulées Loc N2 =: à N2 destination, etc.                               |
| (lexicale)      | Exemple : Max a découché de chez Léa; Max s'en vient chez vous                                    |

TABLE 3.2: Extrait de la documentation des propriétés lexicales

| No =: Nhum | N0 =: Nnc | <ent>Ppv</ent> | Ppv ≕ se figé | <ent>V</ent> | Aux =: avoir | Aux =: être | N0 est Vpp W | No V | Prép1               | N1 =: Qu Pind | N1 =: Qu Psubj | Prép V0-inf $W=Ppv$ | N0 V Prép N1hum | N0 V Prép N1-hum | Prép N $1={\sf Ppv}$ | N0 V dans N1 | N0 V N1hum | N0 V N1-hum | <opt></opt>                        |
|------------|-----------|----------------|---------------|--------------|--------------|-------------|--------------|------|---------------------|---------------|----------------|---------------------|-----------------|------------------|----------------------|--------------|------------|-------------|------------------------------------|
| +          | -         | < E >          | -             | achever      | +            | _           | -            | -    | de                  | -             | _              | _                   | _               | -                | -                    | -            | +          | +           | Max achève de peindre le mur       |
| +          | +         | < E >          | -             | aller        | _            | _           | -            | -    | $\langle E \rangle$ | $\exists$     | _              | _                   | -               | -                | -1                   | -            | -          | $\exists$   | Le verre va tomber                 |
| +          | -         | s'             | +             | avancer      | _            | +           | _            | -    | à                   | -             | _              | _                   | _               | -                | -                    | -            | -          | -           | Max s'avance à dire que c'est faux |

Table 3.3: Extrait de la table 1 des verbes distributionnels

dans l'entrée verbale. C'est pourquoi dans l'exemple revenir, nous avons les deux colonnes Ppv =: Neg et Neg codées +. Ces deux colonnes sont toujours codées + pour les entrées accompagnées du clitique ne figé avec le verbe, sauf pour l'entrée savoir de la table 1, qui sans adverbe négatif a un autre sens : Luc ne saurait dormir différent de Luc n'arrête pas de dormir.

Un autre exemple, donné à la Fig. 3.4, montre un extrait de la table FNAN des noms prédicatifs. Ce sont des noms avec argument(s) étudiés avec leur verbe support.

Dans les phrases à verbe support, ce n'est pas le verbe qui remplit la fonction de prédicat de la phrase, mais un nom prédicatif (*Luc monte une* attaque *contre le fort*), un adjectif prédicatif (*Luc est* fidèle à ses idées), etc. La distribution du sujet, et éventuellement des compléments essentiels, dépend de cet élément prédicatif. Un verbe support a la particularité de pouvoir s'effacer :

Je connais un politique qui est fidèle à ses idées

= Je connais un politique fidèle à ses idées

Fidèle à ses idées, il a démissionné

Les noms prédicatifs de la table FNAN ont pour verbe support *faire* et entrent dans la construction N0 faire Det N à N1, où le sujet et l'objet indirect sont obligatoirement des noms humains. Cela signifie qu'elle est composée des noms ayant l'ensemble des propriétés N0 faire Det N à N1, N0 =: Nhum et N1 =: Nhum vraies, et les propriétés N0 =: N-hum et N1 =: N-hum fausses. Cette table reconnaît par exemple, le nom *canular* dans la phrase *Max fait un canular à Marie*.

Un exemple appartenant à la classe des expressions figées est donné à la Fig. 3.5. C'est un extrait de la table C6, laquelle accepte la construction N0 V N1 Prép2 Det2 C2. Cette table reconnaît l'expression figée avoir sur le cœur, mais aussi n'en penser pas moins, où certains éléments de l'entrée sont vides (ici, Prép2 et Det2).

Enfin, la Fig. 3.6 est un extrait de la table PC des adverbes, regroupant les adverbes qui ont la structure Prép C (sans déterminant et sans modifieur). Cette table reconnaît par exemple, l'adverbe figé de visu avec le prédicat type juger, qui n'est donné qu'à titre indicatif.

| <ent>N</ent>   | autre Det           | Det =: un | Det =: un-Modif | Det =: du | Det =: des | NO faire le N de V0-inf W | N0hum faire Det N à N1hum sur ce point |
|----------------|---------------------|-----------|-----------------|-----------|------------|---------------------------|--|
| cadeau         | < <i>E</i> >        | +         | +               | _         | +          | +                         |  |
| calembour      | $\langle E \rangle$ | +         | +               | _         | +          | -                         | +                                      |
| câlin          | $\langle E \rangle$ | +         | +               | _         |            | -                         | -                                      |
| canular        | $\langle E \rangle$ | +         | +               | _         | +          | +                         | +                                      |
| car ambouilles | $\langle E \rangle$ | _         |                 | _         | +          | -                         |  |
| cardiogramme   | < E >               | +         | +               | _         | +          | -                         |  |

TABLE 3.4: Extrait de la table FNAN des noms prédicatifs

| N0 =: Nhum | N0 =: N-hum | Ppv =: en figé | =: Ne | <ent></ent>         | <ent>V</ent>  | NO V N1 | N1 =: Nhum | N1 =: N-hum | N1 =: Qu Pind | Qu Pind = V0-inf W | Qu Pind = Aux V0-inf W | Qu Pind = de V0-inf W | N1 =: Qu Psubj | Qu Psubj = V0-inf W | Qu Psubj = de V0-inf W | N1 =: si P | Qu P = Ppv | N1 =: le fait Qu P | <ent>Prép2</ent> | <ent>Det2</ent> | <ent>C2</ent>       | [passif] | C2 =: C2 de Nhum | C2 de Nhum = Ppv-C2 =: lui-C2 |
|------------|-------------|----------------|-------|---------------------|---------------|---------|------------|-------------|---------------|--------------------|------------------------|-----------------------|----------------|---------------------|------------------------|------------|------------|--------------------|------------------|-----------------|---------------------|----------|------------------|-------------------------------|
| +          | -           | _              | _     | $\langle E \rangle$ | admettre      | +       | _          | +           | +             | -                  | +                      | -                     | -              | _                   | -                      | +          | +          | +                  | sans             | < E >           | $d\'{e}monstration$ | -        | _                |                               |
| +          | -           | _              | _     | $\langle E \rangle$ | avoir         | -       | +          | +           | +             | -                  | _                      | -                     | +              | _                   | +                      | _          | +          | +                  | sur              | le              | cœur                | -        | _                | _                             |
| +          | -           | +              | +     | n'e $n$             | $penser\ pas$ | -       | -          | -           | +             | $\exists$          | +                      | -                     | -              | $\exists$           | -                      | -          | -          | -                  | < <i>E</i> >     | < <i>E</i> >    | moins               | -        | _                |                               |

TABLE 3.5: Extrait de la table C6 des expressions figées

| NO =: Nhum | N0 =: N-hum | Neg obl |                     | Prédicat type    | <ent>Prép</ent> | <ent>C</ent> | N0 V W de (E+Dind) (façon+manière) C-a | N0 V W C-a-ment | Conjonction |                     | C-a-ment            |  |
|------------|-------------|---------|---------------------|------------------|-----------------|--------------|--|-----------------|-------------|---------------------|---------------------|--|
| +          | _           | _       | $\langle E \rangle$ | juger            | de              | visu         | _                                      | _               | _           | $\langle E \rangle$ | $\langle E \rangle$ |  |
| +          | _           | _       | $\langle E \rangle$ | $exp\'erimenter$ | in              | vitro        | _                                      | _               | _           | $\langle E \rangle$ | $\langle E \rangle$ |  |
| +          | _           | _       | $\langle E \rangle$ | $exp\'erimenter$ | in              | vivo         | _                                      | -               | _           | $\langle E \rangle$ | $\langle E \rangle$ |  |
| +          | _           | _       | $\langle E \rangle$ | faire N          | à               | $volont\'e$  | _                                      | =               | -           | $\langle E \rangle$ | $\langle E \rangle$ |  |

TABLE 3.6: Extrait de la table PC des adverbes

Actuellement, pour le français, nous disposons de 67 tables (et donc classes) de verbes distributionnels simples, la catégorie la mieux décrite, 78 tables de noms prédicatifs <sup>4</sup> simples et composés, 69 tables d'expressions figées <sup>5</sup> (principalement verbales et adjectivales) et 32 tables d'adverbes (adverbes en *-ment* et locutions adverbiales) <sup>6</sup>.

Le nombre d'entrées est d'environ 13 800 pour les verbes distributionnels, 12 600 pour les noms prédicatifs, 39 600 pour les expressions figées et de 10 400 pour les adverbes (plus de détails seront donnés dans la section 6.6).

L'ensemble des tables est téléchargeable sous une licence libre (LGPL-LR) sur le site http://infolingu.univ-mlv.fr (Données Linguistiques > Lexique-Grammaire > Téléchargement).

<sup>4.</sup> Sans compter les 5 tables de L. Pivaut qui viennent d'être numérisées sans avoir été corrigées manuellement et ne sont pas encore disponibles (voir 5.5.2).

<sup>5.</sup> Sans compter 3 tables de L. Danlos (ZD, ZM et Z) qui n'ont pas été numérisées (voir 5.5.2).

<sup>6.</sup> Sans compter 3 tables d'adjectifs non prédicatifs simples, et 38 tables d'adjectifs prédicatifs simples qui sont en cours d'élaboration, afin de remplacer les 13 tables de L. Picabia qui n'ont pas été numérisées (voir 5.5.2).

4

## Le lexique syntaxique Lefff et l'analyseur syntaxique FRMG

Dans ce chapitre, nous décrivons dans la section 4.1 le format TAL dans lequel nous avons converti les tables. Il s'agit du format Alexina, qui est celui du lexique syntaxique Lefff, utilisé par l'analyseur FRMG, dont nous expliquons en détail le fonctionnement dans la section 4.2. L'ensemble de ces ressources sont incluses dans la chaîne de traitement ALPAGE (Cabrera, 2008).

#### **4.1** Le lexique syntaxique Lefff et le format Alexina

Le Lefff (Lexique des Formes Fléchies du Français) est un lexique morphologique et syntaxique à large couverture pour le français (Sagot et Danlos, 2007; Sagot, 2010). Il peut être utilisé directement dans les applications de TAL de haut niveau, y compris celles qui nécessitent une analyse syntaxique profonde. Il contient 536 375 entrées correspondant à 110 477 lemmes distincts couvrant toutes les catégories. Toutes les entrées sont fléchies lors de la compilation du lexique. Il est téléchargeable sous une licence libre (LGPL-LR) sur le site http://gforge.inria.fr/projects/alexina/.

Le développement du Lefff repose sur une architecture d'acquisition et de modélisation de lexiques morphologiques et syntaxiques, nommée Alexina (Architecture pour les LEXiques INformatiques et leur Acquisition), dans laquelle des lexiques pour d'autres langues sont en cours de développement (espagnol, polonais, slovaque, etc.).

Alexina permet de décrire les informations morphologiques et syntaxiques de manière lisible, complète et efficace. Sa flexibilité permet de représenter un grand nombre de phénomènes à travers un format simple, directement utilisable par les divers formalismes grammaticaux (dont LFG et LTAG) qui nécessitent des informations syntaxiques

détaillées.

La dernière version du Lefff est la version 3. Elle fait usage de la notion de redistribution : le lexique *intensionnel*, édité par les développeurs du lexique, associe à chaque entrée un cadre de sous-catégorisation <sup>1</sup> canonique, et liste les redistributions possibles à partir de ce cadre. Le processus de *compilation* du Lefff intensionnel en Lefff extensionnel fléchit les lemmes et construit les différentes entrées pour ces différentes redistributions.

Malgré les différences de représentation linguistique entre le Lefff et le Lexique-Grammaire, nous avons pu convertir la majorité des informations syntaxiques contenues dans le Lexique-Grammaire au format Lefff, sans avoir à modifier le format d'origine <sup>2</sup>.

À présent, nous listons les sources des informations lexicales, ainsi que les données quantitatives du Lefff (4.1.1). Ensuite, nous détaillons le processus de compilation du Lefff intensionnel en Lefff extensionnel (4.1.2), puis en Lefff compilé  $(4.1.3)^3$ .

### 4.1.1 Sources des informations lexicales et données quantitatives du Lefff

Les informations lexicales incluses dans le Lefff sont originaires de différents travaux :

- acquisition automatique (avec validation manuelle) à l'aide de techniques statistiques appliquées sur des corpus bruts (Clément *et al.*, 2004; Sagot, 2005);
- acquisition automatique (avec validation manuelle) d'informations syntaxiques atomiques (Sagot, 2006) (chap. 7);
- correction et ajout manuel ou guidé par des techniques automatiques, telles que des statistiques simples sur des corpus étiquetés (Molinero et al., 2009) ou la fouille d'erreurs dans les sorties d'analyseurs syntaxiques (Sagot et de La Clergerie, 2008);
- étude linguistique de certains phénomènes et de leur représentation dans d'autres ressources, conversion (d'une partie) de ces ressources dans le format Alexina, et validation manuelle de leur fusion automatique avec le Lefff; les ressources principalement utilisées sont les tables du Lexique-Grammaire (Gross, 1975), DICOVALENCE (van den Eynde et Mertens, 2006) et LVF (Dubois et Dubois-Charlier, 1997). Cela a été appliqué entre autres à des constructions impersonnelles (Sagot et Danlos,

<sup>1.</sup> La description syntaxique et sémantique du Lexique-Grammaire tient systématiquement compte de plusieurs constructions (la construction de base plus une ou plusieurs autres), alors que dans la littérature le terme de cadre de sous-catégorisation fait généralement référence à une classification fondée sur des critères qui concernent une construction unique. Dans le cas du Lefff, en général une entrée est associée à un cadre de sous-catégorisation canonique, c'est-à-dire ne prenant pas en compte des transformations telles que la passivation, mais qui regroupe plusieurs constructions. Par exemple, l'effacement d'un argument dans une construction est considéré comme une variante de cette construction et est incluse dans le cadre de sous-catégorisation canonique. Mais il est possible d'associer une entrée à plusieurs cadres, pour cela il suffit d'avoir plusieurs entrées ayant le même identifiant. Dans la suite de la thèse, nous emploierons le terme de cadre de sous-catégorisation tel qu'il est utilisé dans le Lefff, c'est-à-dire en y incluant plusieurs constructions, mais sans prendre en compte les transformations.

<sup>2.</sup> Nous verrons en 8.1.4 les informations que nous avons ajoutées.

<sup>3.</sup> Comme cela a été expliqué dans Fernández González (2010) pour le Leffe (Lexique des Formes Fléchies de l'Espagnol).

2007), constructions pronominales (Danlos et Sagot, 2008), les adverbes en -ment (Sagot et Fort, 2007), plusieurs classes d'expressions figées verbales (Laurence et al., 2006), les verbes en -iser et -fier (Sagot et Fort, 2009);

 enfin, un certain nombre des noms et adjectifs viennent initialement du lexique morphologique Multext pour le français (Veronis, 1998).

Au niveau extensionnel, la version actuelle du Lefff (3.0.1) (Sagot, 2010) contient 536 375 entrées correspondant à 110 477 lemmes distincts couvrant toutes les catégories. Les chiffres détaillés figurent dans la Tab.  $4.1^4$ .

| Catégorie    | Entrées intensionnelles | Lemmes distincts | Entrées extensionnelles |
|--------------|-------------------------|------------------|-------------------------|
| Verbes       | 7 107                   | 6 825            | 361 817                 |
| Verbes figés | 1 868                   | 1 850            | 3 295                   |
| Noms         | 37 755                  | 37 530           | 78 338                  |
| Adjectifs    | 10 504                  | 10 483           | 34 096                  |
| Adverbes     | 4 019                   | 3 584            | 4 062                   |
| Prépositions | 226                     | 225              | 655                     |
| Noms propres | 52 482                  | 52 185           | 52 552                  |
| Autres       | 833                     | 632              | 1 342                   |

Table 4.1: Données quantitatives du Lefff

#### **4.1.2 Du** Lefff intensionnel au Lefff extensionnel

Le Lefff est basé sur deux niveaux de représentation :

- Un niveau intensionnel qui factorise l'information lexicale, de sorte qu'à chaque lemme soit associé une classe morphologique<sup>5</sup> et une information syntaxique détaillée permettant une gestion rapide et simple. L'information lexicale sous forme intensionnelle est organisée dans différents fichiers .ilex en fonction de la catégorie lexicale de leurs lemmes.
- Un niveau extensionnel, généré automatiquement en compilant le lexique intensionnel (tous les fichiers .ilex), dans lequel on associe chaque forme fléchie 6 avec toute son information morphologique et syntaxique : étiquette morphologique, ou cadre de sous-catégorisation de sa redistribution correspondante, etc. Par ce processus on obtient les fichiers sous la forme extensionnelle .lex, correspondant à chacun des fichiers .ilex compilés.

Lorsque le lexique intensionnel est compilé en un lexique extensionnel, tous les mots appartenant à la famille de chaque lemme sont construits à l'aide de leur classe

<sup>4.</sup> La catégorie «Autres» comprend les différentes sortes de conjonctions, les déterminants, les interjections, les signes de ponctuation, les pronoms, les préfixes et suffixes, ainsi que des entrées spéciales pour les entités nommées et les mots inconnus.

<sup>5.</sup> Une classe morphologique permet de construire toute les formes associées au lemme.

<sup>6.</sup> Par *forme fléchie*, on entend chaque mot résultant de l'application de règles de dérivations sur la racine d'un certain lemme. Dit d'une autre manière, la forme fléchie est le mot tel qu'il apparaît.

morphologique<sup>7</sup>. Les classes morphologiques sont définies dans un format qui couvre la plupart des entrées du lexique. Seuls les lemmes qui se fléchissent d'une manière irrégulière sont décrits manuellement dans un fichier avec extension .mf.

Chaque entrée dans le lexique intensionnel est généralement définie par un lemme et une catégorie lexicale. Toutefois, il est possible de trouver plusieurs entrées avec le même lemme et la même catégorie lexicale, mais dans ce cas certaines informations morphologiques et syntaxiques diffèrent. Cela permet de diviser un lemme en différents sens sémantiques impliquant des constructions syntaxiques différentes. Cette distinction est conservée une fois le lexique compilé grâce à une numérotation (\_\_\_1) attachée au lemme qui est différente pour chaque entrée lexicale ayant un sens différent.

Une entrée intensionnelle contient les informations suivantes :

- une **classe morphologique**, qui définit les patrons qui construisent toutes les formes fléchies du lemme;
- un poids, qui désigne la fréquence d'apparition d'un mot dans la langue française (dans le but d'aider l'analyseur syntaxique à privilégier une entrée plutôt qu'une autre): le poids standard est de 100, puis de rares entrées ont le poids 200, 300, 400 ou 600, comme par exemple l'auxiliaire avoir;
- une catégorie lexicale, choisie parmi un ensemble d'étiquettes possibles. Les catégories lexicales sont divisés en deux types : ouvertes <sup>8</sup> (aussi appelées productives) et fermées <sup>9</sup> (aussi appelées grammaticales);
- un cadre de sous-catégorisation, qui montre explicitement comment le lemme peut être utilisé dans une construction syntaxique particulière. Cette liste énumère les fonctions syntaxiques des arguments possibles du lemme, et la réalisation possible de chacune de ces fonctions;
- les possibles redistributions, qui définissent comment les cadres de souscatégorisation de base se transforment pour construire les autres cadres de souscatégorisation.

Soit par exemple l'entrée intensionnelle suivante :

Elle décrit une entrée du lemme verbal *clarifier*, qui est transitive directe. Elle a deux arguments réalisés canoniquement par les fonctions syntaxiques *Suj* et *Obj*, qui

<sup>7.</sup> Cette compilation se fait avec Alexina-tools.

<sup>8.</sup> Les catégories *ouvertes* sont : adjectifs, adverbes, verbes, noms, etc. Par flexion, dérivation, inclusion de néologismes, il est possible d'ajouter de nouvelles formes.

<sup>9.</sup> Les catégories *fermées* sont : prépositions, pronoms, conjonctions, etc. Elles ne permettent pas d'ajouter de nouvelles formes.

sont décrites entre les chevrons et dont la deuxième est facultative (symbolisé par les parenthèses). Elle admet les redistributions fonctionnelles (préfixées par le symbole %) actif (la distribution par défaut), passif, passif impersonnel (Il a été clarifié par Pierre que Luc était le coupable), se moyen impersonnel (Il s'est clarifié de nombreuses choses à cette réunion) et participe passé employé comme adjectif (Les règles sont clarifiées). Sa classe morphologique est v-er:std (classe standard des verbes du premier groupe), sa catégorie lexicale est v, et son poids est de 100 (poids par défaut).

À titre d'exemple, l'entrée extensionnelle pour la forme fléchie clarifiés et la redistribution passif a la forme simplifiée suivante :

Les fonctions syntaxiques sont définies dans le Lefff par des critères proches de ceux de DICOVALENCE (van den Eynde et Mertens, 2006), qui reposent sur la substituabilité (en prenant en compte pronoms et syntagmes), sur le principe de réalisation unique d'une fonction syntaxique pour un prédicat donné, et sur l'identification de la fonction par un paradigme de pronoms (à l'exception des cas à partage d'arguments, c'est-à-dire les attributs).

L'inventaire des fonctions syntaxiques, ainsi que leurs critères définitoires décrits dans (Sagot et Danlos, 2007; Sagot, 2010) sont les suivants :

- Suj pour sujet : la forme clitique est celle d'un clitique nominatif;
- Obj pour objet direct : la forme clitique est celle d'un clitique accusatif, substituable par ceci/cela, translaté par passivation lorsque c'est possible;
- Objà pour objet indirect canoniquement introduit par la préposition à : substituable par  $\grave{a}+pronom$  non clitique mais pas par ici ou  $l\grave{a}(-bas)$ , cliticisation possible à l'aide du clitique datif ou du clitique locatif y;
- Objde pour objet indirect introduit par la préposition de: cliticisation à l'aide du clitique génitif en, non substituable par d'ici ou de la;
- Loc pour argument locatif : substituable par *ici* ou *là(-bas)*, cliticisation à l'aide du clitique locatif y (*Pierre va* à **Paris**);
- Dloc pour argument délocatif : substituable par d'ici ou de là, cliticisation à l'aide du clitique génitif en (Pierre vient de Paris);
- Att pour attribut (du sujet, de l'objet ou de l'à-objet) et pseudo-objet (J'ai acheté ceci 3 euros);
- Obl et Obl2 pour les autres arguments obliques (non cliticisables); Obl2 est utilisé
  pour les verbes ayant deux arguments obliques, tel que plaider auprès de quelqu'un
  en faveur de quelqu'un d'autre.

Chaque fonction syntaxique peut être réalisée par différentes réalisations, qui sont de trois types :

- pronom clitique: cln pour clitique nominatif (Il donne ce livre à Marie), cla pour clitique accusatif (Il le donne à Marie), cld pour clitique datif (Il lui donne ce livre),
   y pour clitique locatif (Max y va), en pour clitique génitif (Max en mange);
- syntagme direct : sn pour syntagme nominal (**La belle dame** arrive), sa pour syntagme adjectival (La robe est **verte**), sinf pour syntagme infinitif (Pierre est parti dire aurevoir), scompl pour syntagme phrastique fini (Pierre dit que Marie est belle), qcompl pour interrogative indirecte (Pierre dit combien il gagne);
- syntagme prépositionnel : un syntagme direct précédé d'une préposition, comme de-sn, à-sinf ou pour-sa; à-scompl et de-scompl représentent les réalisations en a/de ce que P).

Enfin, une fonction dont la réalisation est facultative voit sa liste de réalisations possibles mise entre parenthèses.

Des informations syntaxiques complémentaires (contrôle, mode des complétives, etc.) sont notées par des *macros* (@CtrlSujObj, @ComplSubj, etc.) dont l'interprétation formalisée dépend du contexte d'utilisation (voir 8.1.4).

#### 4.1.3 Du Lefff extensionnel au Lefff compilé

Le Lefff sous forme extensionnelle doit être compilé par le lexicaliseur Lexed pour être utilisé dans les analyseurs syntaxiques basés sur des méta-grammaires <sup>10</sup>. Pour cela, les informations morpho-syntaxiques présentes dans les différents fichiers du Lefff extensionnel doivent être rassemblées en un seul fichier, dico.xlfg, qui est ensuite compilé par Lexed en un automate à états finis dans le fichier dico.xlfg.fsa.

FRMG Lexer utilise ce Lefff compilé pour étiqueter les unités lexicales d'un texte donné en entrée avec les informations morpho-syntaxiques.

Les informations du Lefff compilé sont adaptées par FRMG Lexer au format de FRMG. Par exemple, la catégorie lexicale adjectif est désignée par un a dans le lexique Lefff, tandis que FRMG Parser note les adjectifs par adj. La même chose se produit avec les pronoms (p et pro) ou des adverbes (r et adv). En revanche, la catégorie lexicale verbe est désignée par v aussi bien dans le Lefff compilé que dans l'analyseur syntaxique

L'unité lexicale promet est ainsi étiquetée :

<sup>10.</sup> Lexed est inclus dans l'architecture Alexina-tools et distribué sous licence GPL : http://www.labri.fr/perso/clement/lexed/

```
number => sg,
                     person => 3,
                     tense => present},
anchor => tag_anchor{ name =>
                   ht{arg0 => arg{function => suj,
                                   kind => subj,
                                   pcas => (-),
                                   real => cat[cln,'CS','S','N2',
                                               prel,pri,'PP',(-)]},
                      arg1 => arg{function => obj,
                                   kind => kind[obj,prepvcomp,scomp,
                                                                (-)],
                                   pcas => prep[de,(-)]},
                      arg2 => arg{function => 'objà',
                                   kind => kind[prepobj,(-)],
                                   pcas => prep['à',(-)]},
                   ctrsubj => subj,
                   diathesis => active,
                   imp => '-',
                   refl => (-)},
 coanchors => [],
 equations => []
```

Ce format, également utilisé par l'analyseur syntaxique FRMG *Parser*, est appelé hypertag. La structure d'un hypertag est la suivante :

- lex: le mot (forme) auquel est attribué l'hypertag tel qu'il apparaît dans le Lefff.
- truelex : le mot tel qu'il apparaît dans le texte d'entrée. Il peut ne pas correspondre à sa forme correspondante du Lefff pour cause de contraction orale ou écrite, fautes d'orthographe, etc.
- lemma : le lemme de la forme en question.
- cat : la catégorie lexicale du mot.

}

- top : des informations plus détaillées à propos de la forme, telles que le genre, le nombre, la personne, le mode, la diathèse, l'auxiliaire requis, etc.
- anchor : les informations syntaxiques présentes dans l'entrée extensionnelle faisant référence à des arguments du cadre de sous-catégorisation <sup>11</sup>, la redistribution, si elle est ou non impersonnelle (*imp*) et si elle est ou non réflexive (*refl*). Ce sont des informations spécifiques qui servent de liaison entre le lexique et la syntaxe. L'information contenue dans le champ *anchor* de l'hypertag décrit la structure représentant

<sup>11.</sup> kind et pcas sont des attributs de chaque argument du cadre de sous-catégorisation : le premier décrit les fonctions syntaxiques qui peuvent avoir un argument particulier du verbe, le second énumère l'ensemble (éventuellement vide) des prépositions pouvant précéder l'argument. Il y a deux attributs supplémentaires, qui ne sont pas présents dans l'exemple : real (réalisations possibles des fonctions syntaxiques) et extracted (indique si l'argument se trouve dans une une position non canonique).

le mot lors de l'analyse syntaxique.

On retrouve dans un hypertag l'ensemble des informations présentes dans la forme extensionnelle correspondant à l'unité lexicale, restreint aux types de traits supportés par FRMG Parser<sup>12</sup>.

#### 4.2 L'analyseur syntaxique FRMG

L'ensemble des hypertags fourni par FRMG Lexer est l'entrée immédiate de FRMG Parser, responsable de la prochaine étape dans la chaîne de traitement linguistique : l'analyse syntaxique. FRMG Parser est un analyseur profond à large couverture pour le français. Une description grammaticale de haut niveau, sous la forme de méta-grammaire (appelée également FRMG, tout comme l'analyseur syntaxique), sert de point de départ pour générer une grammaire d'arbres adjoints (TAG, Tree Adjoining Grammar) (Joshi et al., 1975; Abeillé, 2002) par MGCOMP (de La Clergerie, 2005b) (4.2.1). Cette grammaire TAG est transformée par l'environnement DyALog (de La Clergerie, 2005a) en un analyseur syntaxique (4.2.2). Enfin, la sortie de l'analyse est traitée par la ressource Forest utils (4.2.3) <sup>13</sup>. Rappelons que l'ensemble de ces ressources sont incluses dans la chaîne de traitement ALPAGE (Cabrera, 2008).

#### **4.2.1** FRMG et MGCOMP

Les grammaires TAG sont formées d'arbres partiels d'analyse, appelées arbres élémentaires, et qui sont de deux types : arbres initiaux sur lesquels on peut effectuer l'opération de substitution, et arbres auxiliaires, utilisés pour les insertions répétables, et sur lesquels on peut effectuer l'opération d'adjonction. Un nœud feuille étiqueté par un non terminal peut être substitué par un arbre initial  $\alpha$ , comme le montre la Fig. 4.1. Une adjonction insère le contenu d'un arbre auxiliaire  $\gamma$  au niveau d'un nœud X, en découpant  $\gamma$  en deux parties. Le noeud X situé dans la partie supérieure (top) de  $\beta$  est remplacé par la racine de  $\gamma$ , le noeud X racine de la partie inférieure (bottom) de  $\beta$  est remplacé par le noeud pied de  $\gamma$ . Un exemple est donné à la Fig. 4.2.

Les FTAG (Feature-Based TAG) (Vijay-Shanker, 1987) sont une variante usuelle de TAG, dans laquelle les nœuds sont décorés par une paire d'attributs top et bot, généralement exprimés comme des structures de traits.

Pour couvrir le plus largement possible les constructions syntaxiques d'une langue donnée, il est nécessaire de décrire un maximum de structures élémentaires. La taille des grammaires à large couverture fait que leur conception et leur maintenance est une tâche difficile, nécessitant que celle-ci soit (semi-)automatique. En effet, le domaine de localité propre aux arbres TAG implique une explosion combinatoire du nombre d'arbres, ainsi que de leurs sous-arbres correspondants. Par exemple, la structure d'un arbre verbal se

<sup>12.</sup> Le Lefff dispose d'informations morpho-syntaxiques d'un niveau plus profond que FRMG Parser est capable d'utiliser actuellement.

<sup>13.</sup> Comme cela a été expliqué dans Fernández González (2010) pour SPMG (SPanish MetaGrammar), l'analyseur syntaxique de l'espagnol.




FIGURE 4.1: Exemple de substitution




FIGURE 4.2: Exemple d'adjonction

trouve dans tous les arbres ancrés par des verbes. Modifier la description d'un des sousarbres de l'arbre verbal implique à priori la modification de tous les arbres contenant cet arbre verbal, ce qui entraı̂ne des problèmes de maintenance. Les méta-grammaires (Candito, 1999) fournissent une solution élégante dans ce contexte, en évitant l'explosion combinatoire (Thomasset et de La Clergerie, 2005). Ce type de structures est un outil permettant de faire face aux problèmes apparus dans le développement de larges grammaires TAG (Martin, 2006).

Les méta-grammaires introduisent un haut niveau d'abstraction dans la description des restrictions sur et entre les nœuds qui définissent les structures syntaxiques élémentaires de la langue, en les combinant en classes relativement simples, insérées dans une hiérarchie d'héritage multiple. Parmi ces restrictions, on peut citer le domaine (strict ou immédiat) d'un nœud sur un autre, la précédence linéaire, ainsi que les restrictions de décoration (pour les structures de traits) sur les nœuds ou sur la classe (Thomasset et de La Clergerie, 2005). Cette description grammaticale de haut niveau sert de point de départ pour la génération d'une grammaire TAG pour une langue spécifique. Une méta-grammaire pour le français a été développée (FRMG, FRench MetaGrammar), afin d'obtenir une grammaire TAG pour le français. Les méta-grammaires, y compris FRMG, ont les caractéristiques suivantes (Martin, 2006):

- Restrictions topologiques : chaque classe de la hiérarchie contient une description partielle de la structure des arbres TAG élémentaires. Pour cela, on emploie les relations suivantes :
  - (=) égalité : deux identifiants de nœuds reliés par l'opérateur d'égalité sont équivalents, c'est-à-dire les deux identifiants se réfèrent à un même nœud.
  - (<) précédence : indique l'ordre entre deux nœuds frères.
  - (>>) domination immédiate ou directe : un nœud domine directement un autre,

- lorsque le premier est le père du second.
- (>>+) domination indirecte : un nœud domine indirectement un autre, lorsque le premier est ancêtre non direct du deuxième. Un ancêtre non direct signifie que le nœud situé à un niveau supérieur de l'arbre (nœud dominant) n'est pas le père du nœud dominé.
- Description partielle d'arbre et arbres TAG minimaux : les arbres décrits sont souvent des quasi-arbres (Rogers et Vijay-Shanker, 1992). Un quasi-arbre est une description permettant de construire un nombre infini d'arbres satisfaisant les restrictions.
- Restrictions de l'unification : restrictions supplémentaires décrites par des déclarations ou des équations de structures de traits attribuées à certains nœuds ou classes, et sujets à l'unification.
- Ressources et besoins : chaque classe peut être consommatrice ou fournisseur d'une ou plusieurs ressources particulières interprétées comme des fonctions syntaxiques (la concordance, par exemple). Chaque ressource peut être consommée directement au niveau de la classe ou par un espace de noms. Les espaces de noms permettent à une classe de demander plusieurs fois la même ressource, aussi longtemps que la demande se situe dans des espaces de noms différents pour éviter les conflits. Par exemple, une ressource de concordance en genre et nombre, entre un nœud et son père, sera requise à plusieurs reprises par différentes classes.
- Gardes : une classe peut contenir des gardes sur certains nœuds. Une garde est une restriction conditionnelle qui, en fonction de l'existence d'un nœud particulier, conduit à la validation ou le rejet des équations de structures de traits décrites dans la partie droite de la garde. Une garde est exprimée par des équations de chemins. Celles-ci sont de la forme :

- Langage concret de la méta-grammaire : pour implémenter les classes de la méta-grammaire qui décrivent un langage donné, on utilise un formalisme concret (de La Clergerie, 2005b).

Voici un exemple de la classe représentant les noms communs  $^{14}$  :

<sup>14.</sup> L'exemple a été simplifié et réunit les classes \_cnoun et cnoun.

```
8:
       Nc=Anchor;
9:
10:
       node N : [cat: N];
       node det : [cat: det, type: subst];
11:
12:
       node Nc : [cat: nc];
13:
15:
       node(det).top.number = node(N2).bot.number;
15:
       node(det).top.gender = node(N2).bot.gender;
       node(det).top.wh = node(N2).bot.wh;
16:
17:
       node(Anchor).bot.person = value(3);
       node(N2).bot.time = node(Nc).top.time;
18:
19:
       node(N2).bot.hum = node(Nc).top.hum;
20:
21:
       - nc::agreement; Nc = nc::N;
22:
       - n::agreement; N = n::N;
23:
       det =>
24:
25:
           node(N2).bot.sat = value(+);
       ~ det =>
26:
27:
           node(N2).bot.sat = value(-);
28:
           node(N2).bot.wh = value(-),
29: }
```

La ligne 3 indique que la classe cnoun hérite de la classe mère noun. Les lignes 4 à 7 déclarent les relations topologiques, qui doivent maintenir les nœuds impliqués dans le fragment de l'arbre décrit. Notons que le nœud det doit précéder le nœud N (ligne 7). L'arbre auquel nous nous référons apparaît à la Fig. 4.3. Le nœud Nc est l'ancre de l'arbre (ligne 8).



FIGURE 4.3: Structure syntaxique d'un syntagme nominal

Les lignes 10 à 12 déclarent directement les structures de traits pour les nœuds N, det et N2. Les lignes 14 à 19 expriment des restrictions d'unification avec des équations de chemins. Concrètement, dans ces restrictions s'établissent la concordance en genre et nombre, entre les nœuds det et N2. On vérifie également si les deux nœuds appartiennent à une phrase interrogative (wh) et on définit que la personne d'un nom commun est la troisième. De plus, on établit la concordance en temps et trait humain, entre les nœuds N2 et Nc.

Les lignes 21 et 22 indiquent que la classe cnoun requiert deux fois la ressource agree-ment (concordance) sur des espaces de noms différents. Cette ressource est fournie par une autre classe de la méta-grammaire qui a un nœud nommé N.

La première garde, présente dans les lignes 24 et 25, indique que si le substantif défini par la classe possède un déterminant (det), alors le syntagme nominal qui les réunit tous les deux (N2) est saturé. La seconde garde, qui occupe les lignes 26 à 28, décrit que si le substantif n'est pas accompagné d'un déterminant, il n'est pas saturé. La négation est écrite avec le signe  $\sim$ . De plus, il ne s'agit pas d'un syntagme nominal interrogatif, mais d'un syntagme nominal à l'intérieur d'une phrase interrogative. Cette garde se base sur l'idée qu'un substantif, dans une phrase interrogative, est toujours accompagné d'un déterminant interrogatif. Ainsi, le déterminant quelle accompagne le substantif maison dans la phrase  $Quelle\ maison\ est\ la\ tienne\ ?$ 

La méta-grammaire FRMG est ensuite compilée en une grammaire TAG par le compilateur MGCOMP (Thomasset et de La Clergerie, 2005).

#### **4.2.2 DyALog et** FRMG *Parser*

À partir de la grammaire TAG du français et de DyALog (de La Clergerie, 2005a; de La Clergerie, 2002), on obtient un analyseur syntaxique profond, robuste, hybride TAG/TIG et à large couverture pour le français, nommé FRMG Parser.

Les grammaires d'insertion d'arbres (TIG, Tree Insertion Grammar) (Schabes et Waters, 1995) sont une variante des TAG restreignant les arbres auxiliaires de sorte qu'ils ne puissent s'insérer qu'à droite ou à gauche du nœud d'adjonction. Cette condition implique en particulier que les arbres auxiliaires aient leur dorsale (c'est-à-dire le chemin de la racine au pied) comme frontière gauche ou droite. L'intérêt majeur des grammaires TIG provient du fait qu'elles sont analysables, comme les CFG, avec une complexité en  $O(n^3)$  alors que les TAG le sont en  $O(n^6)$ , où n dénote la longueur de la chaîne d'entrée. De plus, la plupart des grammaires TAG sont essentiellement TIG et il est en fait possible de construire des analyseurs syntaxiques hybrides TAG/TIG (Alonso et Díaz, 2003). DyALog peut analyser une grammaire TAG pour identifier les parties TIG afin de construire de tels analyseurs hybrides TAG/TIG.

À la différence d'autres grammaires TAG à large couverture comprenant plusieurs milliers d'arbres, FRMG *Parser* se caractérise par un très faible nombre d'arbres (moins de 200 arbres). Ceci est réalisé grâce à la capacité descriptive des méta-grammaires et aux mécanismes de factorisation fournis par DyALog (de La Clergerie *et al.*, 2009).

DyALog est un environnement de compilation et d'exécution des analyseurs syntaxiques tabulaires (de La Clergerie, 2005a; Alonso et al., 1999). Une de ces caractéristiques étant la réalisation d'une analyse préliminaire de la grammaire TAG, pour déterminer quels sont les arbres pouvant être compilés en arbres TIG, en raison de leur complexité moindre. Afin de réduire le nombre d'arbres dans la grammaire TAG, DyALog effectue un processus de factorisation en appliquant des opérateurs sur les sous-arbres de la grammaire, comme la disjonction, la fermeture transitive ou l'entrelacement de deux séquences de sous-arbres. Ces opérateurs ne changent pas la nature du forma-

lisme des grammaires, mais ils permettent de réduire de façon exponentielle le nombre d'arbres qui composent la grammaire TAG (de La Clergerie *et al.*, 2009). Cela permet de disposer d'une grammaire beaucoup plus compacte et efficace lors de la construction de l'analyseur syntaxique.

D'autre part, DyALog n'impose pas de restrictions de lexicalisation sur les arbres de la grammaire TAG. Ainsi, certains arbres de la grammaire TAG pour le français ne sont pas ancrés.

La complexité des arbres qui composent la grammaire TAG est illustrée par la Fig. 4.4, qui présente une vue simplifiée d'un arbre verbal canonique pour la voix active. Il s'agit de l'arbre #111, qui résulte du croisement de 25 classes terminales, comprend 43 nœuds et est contrôlé par 35 gardes, où : S est la phrase, VMod est un modificateur verbal (incluant le sujet de la phrase), N2 est un syntagme nominal, CS est une subordonnée conjonctive, PP est un syntagme prépositionnel, V1 est un syntagme verbal, Infl inclut le verbe et un clitique nominatif, comp est un attribut, cln est un clitique nominatif, cla est un clitique accusatif, cld est un clitique datif, prep est une préposition, csu est une conjonction subordonnée, advneg est un adverbe de négation, clr est un clitique réflexif, clseq est une séquence de clitiques, et v est le verbe et l'ancre de l'arbre.




FIGURE 4.4: Arbre #111 (simplifié)

Un arbre, tel que celui de la Fig. 4.4, couvre la réalisation de nombreuses constructions syntaxiques. Pour cela, on attribue un hypertag à l'ancre des arbres ancrés (Thomasset et de La Clergerie, 2005). Cet hypertag décrit, par des structures de traits, un ensemble de mots du lexique qui réunissent certaines caractéristiques. Ainsi, un même arbre, comme celui de l'exemple donné, peut réunir la réalisation de plusieurs verbes qui partagent des comportements similaires. Cela permet de réduire considérablement le nombre d'arbres dans la grammaire. L'hypertag de l'ancre d'un arbre se spécialise ou se généralise, en fonction des informations décrites sur lui. Ces étiquettes sont créées pour chaque arbre

par DyALog (de La Clergerie, 2005a) à partir des restrictions décrites par les structures de traits présentes dans la décoration des nœuds et dans les équations des gardes de la méta-grammaire.

Par conséquent, le point d'ancrage entre les mots du texte, déjà étiquetés par FRMG Lexer avec des hypertags, et les arbres de la grammaire TAG, est réalisé par l'unification des structures de traits des étiquettes des mots avec celles associées aux arbres. Cette opération permet de sélectionner les arbres autorisés pour un mot particulier.

La Fig. 4.5 montre l'hypertag associé à l'arbre #111, alors que la Fig. 4.6 montre l'étiquette correspondant au verbe *promettre* présent dans le lexique Lefff.

Parmi tous les arbres présents dans la grammaire TAG du français, on sélectionne uniquement ceux dont les hypertags s'unifient correctement avec ceux assignés aux mots du texte d'entrée. Dans le cas présent, l'hypertag de la forme promettre s'unifie convenablement avec l'arbre #111 correspondant. Dans les deux étiquettes, on retrouve une construction verbale canonique, qui autorise un objet et un groupe prépositionnel introduit par la préposition  $\dot{a}$ . Par conséquent, la réalisation de l'arbre proposé est permise par le mot promettre.




FIGURE 4.5: Hypertag de l'arbre #111

```
arg0 [kind subj|-
pcas -

arg1 [kind obj|scomp|-]
pcas -

arg2 [kind prepobj|-]
pcas à|-
ref1 -
```

FIGURE 4.6: Hypertag du mot promettre dans le lexique Lefff

Les co-ancres lexicales sont également permises. Il s'agit de permettre l'ajout dans les arbres TAG lexicalisés, d'autres points d'ancrage avec le lexique à part l'ancre principale. Ce sont les co-ancres, qui, contrairement au point d'ancrage principal par les hypertags, se font directement sur le lexique <sup>15</sup>.

À partir de la grammaire TAG factorisée pour le français, DyALog crée un analyseur syntaxique pour le français, reposant sur une stratégie d'analyse tabulaire descendante de la gauche vers la droite : FRMG Parser. Le processus d'analyse syntaxique implique les étapes suivantes :

- 1. Ancrage lexical-syntaxique : On sélectionne l'ensemble des arbres de la grammaire TAG dont les hypertags des ancres s'unifient correctement avec les mots du texte d'entrée. Au terme de cette étape, on dispose d'un ensemble d'arbres liés aux mots remplissant les fonctions syntaxiques principales de la phrase d'entrée <sup>16</sup>. Cependant, les mots avec des rôles secondaires, tels que les déterminants ou les prépositions, ne se lient avec aucune structure <sup>17</sup>.
- 2. Construction de la structure syntaxique : À partir de cet ensemble d'arbres TAG, on essaye de construire la structure syntaxique qui couvre le texte d'entrée, par des opérations de substitution et d'adjonction. Idéalement, à la fin de ce processus, on obtient un arbre dérivé unique. En cas d'ambiguïté syntaxique, cette phase produira plusieurs arbres dérivés décrivant d'une manière différente la structure entière du texte d'entrée.
- 3. **Décoration de la structure syntaxique** : L'arbre dérivé résultant (ou les arbres dérivés) se trouve décoré seulement par les ancres des arbres élémentaires impliqués. Par conséquent, à ce stade, on insère les mots secondaires du texte d'entrée dans les nœuds feuilles de l'arbre final. La décoration s'établit selon l'unification,

<sup>15.</sup> Par exemple, l'arbre modélisant la comparaison Jean est plus grand que Paul, contient la co-ancre lexicale que, étant donné que ce mot se répète dans toutes les constructions de comparaison.

<sup>16.</sup> Il peut s'agir, par exemple, de substantifs comme noyau d'un syntagme nominal ou de verbes comme noyaux de la phrase.

<sup>17.</sup> Sauf si elles ont un rôle décisif dans une certaine construction, une préposition pouvant, par exemple, être l'ancre qui détermine la structure d'un syntagme prépositionnel. L'importance d'un mot ne dépend pas de sa catégorie lexicale, mais de la position qu'il occupe dans la structure analysée.

entre les restrictions incluses dans les nœuds feuilles et les hypertags des mots secondaires impliqués. Elle est réalisée par substitution.

4. Construction de la sortie : L'analyse syntaxique obtenue par FRMG Parser, est retournée sous la forme d'un arbre de dérivation, qui détaille les opérations effectuées pour construire la structure syntaxique de la phrase d'entrée. En cas d'ambiguïté syntaxique, le résultat est une forêt partagée de dérivations. Celle-ci regroupe les arbres de dérivation de chacune des structures syntaxiques acceptées par le texte analysé. Pour cela, une forêt détaille la structure commune des arbres de dérivation résultants et les variations structurelles de chacun d'entre eux.

En outre, DyALog, permet la construction d'analyseurs robustes pouvant fournir, lorsqu'une analyse complète n'est pas possible, l'ensemble des analyses partielles couvrant au mieux le texte d'entrée (de La Clergerie *et al.*, 2009). Ainsi, ce système offre toujours à l'utilisateur une analyse syntaxique, qu'elle soit complète ou partielle.

Notons qu'afin d'améliorer l'utilité de l'analyseur syntaxique, on peut lui imposer une limite de temps, au bout de laquelle les réponses trouvées sont émises même si les calculs ne sont pas finis.

#### **4.2.3 Représentation de l'analyse :** Forest utils

La ressource Forest utils, incluse dans la chaîne de traitement, permet de traiter la sortie de l'analyse, de sorte qu'elle soit utile et compréhensible pour les utilisateurs potentiels de l'application : un utilisateur humain ou une application de TAL de haut niveau.

Pour que l'analyse fournie par la chaîne en construction puisse être utilisée par des applications de TAL de haut niveau, Forest utils représente la forêt de dépendances au format XMLDep (Thomasset et de La Clergerie, 2005). Ce format utilise le standard XML pour décrire les dépendances syntaxiques résultant de l'analyse du texte d'entrée. Les principaux éléments présents dans le format XMLDep sont les suivants :

- Nœud et Cluster : Les clusters, ou groupes de nœuds, représentent les formes présentes dans la phrase analysée. Dans chaque cluster, se trouvent des nœuds étiquetés par un lemme possible de la forme associée au cluster correspondant. À son tour, chaque nœud est décoré, entre autres, avec la catégorie lexicale du lemme, le numéro d'identification de l'arbre TAG dont ce mot est ancre, et un ensemble de dérivations.
- Arc : Les arcs lient un nœud source à un nœud destination et sont décorés par une étiquette indiquant la dépendance syntaxique entre les deux nœuds.

Fondamentalement, on essaye de représenter au format XML un graphe de dépendances constitué de nœuds (lemmes), regroupés en clusters (formes), avec des arcs décrivant les dépendances syntaxiques entre les nœuds.

Pour que les dépendances syntaxiques représentées en XML soient compréhensibles pour un utilisateur humain, il est nécessaire de les transformer en un graphe de dépendances (de La Clergerie et al., 2009).

Le graphe de dépendances de la phrase Jean promet une chanson à Agathe est montré à la Fig. 4.7. Il s'agit d'une représentation graphique du format XMLDep, où les nœuds sont décrits à travers des ellipses jaunes. L'information présente dans chaque nœud est le lemme associé, sa catégorie lexicale et le numéro de l'arbre ancré qu'il représente. Entre parenthèses apparaît le nombre de dérivations en ce nœud. Les nœuds se trouvent inclus dans des clusters, dessinés sous forme de rectangles.

Les dépendances syntaxiques sont représentées par des arcs dirigés et étiquetés par la fonction syntaxique correspondante. Entre parenthèses on indique les dérivations du nœud qui correspondent à cette dépendance. Les arcs de couleur rouge représentent l'opération d'adjonction sur l'arbre indiqué dans le nœud d'origine de l'arc dirigé. Ainsi, dans la Fig. 4.7, l'arbre #25 du nœud S est inséré par adjonction dans l'arbre #198 du nœud promettre. Les arcs de couleur bleue représentent une opération de substitution sur l'arbre du nœud d'origine de l'arc dirigé. Ainsi, l'arbre #59 du nœud chanson est inséré par substitution dans l'arbre #198 du nœud promettre. Un autre type d'arc possible, qui n'apparaît pas ici, est celui de couleur violette, lequel fait référence aux co-ancres lexicales.




FIGURE 4.7: Graphe de dépendances pour Jean promet une chanson à Agathe

Un autre composant important de la chaîne de traitement est le désambiguïsateur, écrit en DyALog, qui permet de ne considérer qu'une analyse par phrase en éliminant l'ambiguïté. Il s'appuie sur un algorithme en programmation dynamique de recherche de la meilleure analyse en sommant les poids des arcs (et, dans une bien moindre mesure, des nœuds) participant à une analyse. Le poids d'un arc résulte de l'accumulation des poids donnés par des règles élémentaires exprimées sous forme de motifs prenant en compte l'arc courant (nœuds source et cible, type, label) et éventuellement les arcs frères, fils ou parents, voire des arcs en compétition. Les poids sont choisis de manière heuristique et ne résultent pas d'un processus d'apprentissage. Le désambiguïsateur comporte plus d'une centaine de règles élémentaires. Par exemple, citons l'existence de règles favorisant les arcs remplissant la valence d'un verbe (sujet, objet, etc.), la présence d'un sujet avant son verbe, l'inversion du sujet si certaines conditions sont remplies, etc. D'autres règles pénalisent les dépendances à longue distance, les transcatégorisations non nécessaires, certaines constructions improbables, etc.

Le coût théorique de l'algorithme est polynomial, conduisant en pratique à des temps de désambiguïsation très longs sur certaines phrases très ambiguës. En moyenne, les temps de désambiguïsation sont du même ordre de grandeur que les temps d'analyse

et donc non négligeables. Par ailleurs, la désambiguïsation est relativement instable, pouvant dramatiquement dépendre de variations sur les poids.

Enfin, dans le cadre des campagnes EASy et Passage, le désambiguïsateur est complété par un convertisseur, écrit en DyALog, vers les formats attendus par les organisateurs. Ces deux formats, très proches, proposent une annotation syntaxique sous forme de groupes non récursifs (GN, GA, GR, GP, NV, PV) et de relations (SUJ-V, AUX-V, COD-V, ATB-SO, CPL-V, MOD-V, MOD-N, MOD-A, MOD-R, MOD-P, COORD, APPOS, JUXT, COMP) entre formes et/ou groupes (cf. 2.1.2). Ces formats sont prévus pour des analyses plus surfaciques que celles rendues par FRMG, amenant à des pertes d'information et à des erreurs pendant la conversion.

Enfin, précisions que FRMG est un logiciel libre, tout comme le Lefff, accessible sous la GForge de l'INRIA <sup>18</sup>. Il est également possible de jouer avec la chaîne de traitement et de visualiser la grammaire FRMG sur http://alpage.inria.fr/frmgdemo.

<sup>18.</sup> http://gforge.inria.fr/projects/mgkit/

# Deuxième partie Modifications des tables

## 5

### Amélioration des tables et création des tables des classes

Ce chapitre décrit avec plus de précision les tables du Lexique-Grammaire, l'intérêt de leur format et les améliorations que nous y avons apportées. Nous avons inclus tout au long de ce chapitre de nombreux exemples, permettant de se familiariser avec les notations des tables. Notons qu'un exemple précédé du signe \* désigne une phrase non acceptable (ou éventuellement acceptable dans un emploi différent de celui qui est envisagé).

Tout d'abord, la section 5.1 contient un inventaire précis des tables, en indiquant leur provenance et en effectuant une sorte d'état des lieux, soulevant l'origine des problèmes de cohérence que les tables contiennent. Ensuite, la section 5.2 met en avant le format d'origine des tables, tout en expliquant leur classification. Puis, nous expliquons comment nous avons formalisé et homogénéisé les propriétés syntaxico-sémantiques dans la section 5.3, en listant les différentes solutions apportées. Dans la section 5.4, nous définissons ce qu'est une table des classes, en expliquant son rôle. Enfin, nous détaillons le codage qu'il reste encore à faire dans la section 5.5. Pour finir, la section 5.6 montre comment l'exploitation des tables du Lexique-Grammaire dans des systèmes de TAL est possible à partir de la version actuelle des tables.

#### 5.1 Provenance des tables et état des lieux

Nous avons commencé par rassembler les informations sur les tables actuellement développées, afin d'en faire un inventaire aussi complet que possible (Tolone, 2009),

figurant dans la Tab.  $5.1^{1}$ . Nous les avons classées par catégories (verbes distributionnels, noms prédicatifs, expressions figées  $^{2}$ , adverbes, adjectifs prédicatifs et adjectifs non prédicatifs). Pour chaque ensemble de tables nous indiquons :

- leur provenance (avec les références des publications concernées);
- le nom des tables (qui n'est pas une liste complète en soit mais qui permet de les identifier en respectant l'ordre alphabétique<sup>3</sup>);
- le nombre de tables concernées (avec entre parenthèses les éventuelles adjonctions récentes détaillées par la suite).

Les tables du Lexique-Grammaire n'ont pas exclusivement été conçues pour être exploitées dans des applications de TAL au début de leur élaboration, vers 1968. Toutefois, leur extension s'est poursuivie, s'est étendue à d'autres langues que le français, et elles restent actuellement utilisées. Cela a fait prendre conscience, à certains des auteurs, des potentialités d'exploitation incluses dans les tables du Lexique-Grammaire. C'est pourquoi, l'équipe d'informatique linguistique du LIGM de l'Université Paris-Est s'est récemment investi dans cette exploitation, notamment grâce à cette thèse et au projet LGTag, qui a impliqué Éric Laporte, Christian Leclère, Stavroula Voyatzi, Takuya Namakura, Matthieu Constant et moi-même. Durant ma thèse, j'ai joué un rôle de coordination entre ces contributeurs, en plus de ma contribution individuelle.

En effet, la plupart des tables constituent autant de fichiers Excel, qui ne forment pas véritablement un tout cohérent. Outre les entrées non encore codées (des signes  $\sim$  remplacent alors les + et les -), ces tables souffrent de diverses formes d'incohérence et d'incomplétude :

- certains intitulés de colonnes diffèrent d'une table à l'autre, bien qu'ils dénotent la même propriété linguistique;
- certains intitulés de colonnes ne dénotent pas la même propriété d'une table à l'autre;
- certains intitulés de colonnes laissent implicites des informations, pourtant nécessaires à leur exploitation automatique;
- des informations importantes ne sont pas représentées, car elles sont considérées comme implicites pour une table donnée.

Tous ces problèmes proviennent du fait que les tables ont été élaborées durant plus de 40 ans par différents auteurs. Elles font souvent partie d'annexes de thèses, certaines, mais pas toutes, ont été reprises ensuite dans la publication de livres. D'autres figurent dans des revues (telles que Lingvisticæ Investigationes ou les Cahiers de Lexicologie) ou des rapports (Rapport de recherche ou Rapport technique du LADL). Chaque auteur apporte sa contribution dans le cadre de son travail de recherche, avec sa propre vision et ses propres notations, tout en respectant le même système de codage (+ et -), représentant l'acceptation ou non de propriétés syntaxico-sémantiques par les entrées

<sup>1.</sup> La Tab. 5.1 est reprise à la Tab. 9.1 afin d'y ajouter les différents formats auxquels les tables ont été converties.

<sup>2.</sup> Les expressions figées ne forment pas en soit une catégorie, mais réunissent un ensemble de catégories, surtout la table C0E, comme nous le verrons en 6.4.1.

<sup>3.</sup> La liste complète des tables avec le nombre d'entrées par table figure dans la section 6.6.

| Références                              | Nom des tables                         | Nombre  | Origine    |
|---|--|---------|------------|
| (a) Verb                                | es distributionnels (simples)          |         |            |
| Gross (1975)                            | 1 à 18                                 | 17 (+1) | Livre      |
| Boons <i>et al.</i> (1976a) (BGL)       | 32A à 32R3, 36R, 38PL, 38R et 39       | 15 (+1) | Rapport    |
| Boons <i>et al.</i> (1976b) (BGL)       | 31H, 31R, 33, 34L0, 35L à 35R          | 8 (+3)  | Livre      |
| Guillet et Leclère (1992) (BGL)         | 36DT, 36SL, 37E à 38LR                 | 16 (+3) | Livre      |
| Leclère (1990), Borillo (1971) (BGL)    | 36S                                    | 1       | Revue      |
| Leclère (1990) (BGL)                    | 35RR et 38RR                           | 2       | Revue      |
| (b) Noms pi                             | rédicatifs (simples et composés)       |         |            |
| Giry-Schneider (1978)                   | F1A à F91                              | 21      | Livre      |
| Giry-Schneider (1987)                   | FN à FNPNN                             | 10      | Livre      |
| Meunier (1981)                          | AN01 à AN06 et ANSY                    | 7       | Thèse      |
| G. Gross (1989)                         | AA, AD, DR1 à ES, FR1 à IS2            | 15      | Thèse      |
| Giry-Schneider et Balibar-Mrabti (1993) | AN07 à AN10                            | 4       | Rapport    |
| Giry-Schneider (2005b)                  | ANDN et ANSN                           | 2       | Revue      |
| de Négroni-Peyre (1978)                 | PSY et SYM                             | 2       | Revue      |
| Vivès (1983)                            | APE1 à APP3                            | 9       | Thèse      |
| Labelle (1974)                          | ANA, ANM à ANS et ANSU                 | 8       | Thèse      |
| Pivaut (1989)                           | FD1 à FD4                              | 5       | Thèse      |
|   | (principalement verbales et adjectival | les)    |            |
| Boons <i>et al.</i> (1976b) (BGL)       | 31I                                    | 1       | Livre      |
| Gross (1982)                            | A1 à E0P1, E01, ECO et YA              | 38      | Revue      |
| Gross (1988)                            | EAPC, ENPC et EPA                      | 3       | Revue      |
| Gross (1996)                            | EPAC à EPDETC                          | 9       | Revue      |
| M. Gross                                | E1, E1HC, E1PN et EDN                  | 4       | Non publié |
| Giry-Schneider (1987)                   | FC à FCPNN                             | 9       | Livre      |
| Danlos (1980)                           | Z à ZS                                 | 8       | Thèse      |
| (d) Adve                                | rbes (simples et (semi-)figés)         |         |            |
| Molinier et Levrier (2000)              | ADVMF à ADVPS                          | 16      | Livre      |
| Gross (1986a)                           | PAC à PVCO                             | 16      | Livre      |
|   |  |         | I          |
|   | ectifs prédicatifs (simples)           | 1.0     |            |
|   | ADJ1 à ADJ13                           | 13      | Livre      |
| J. Giry-Schneider                       | ADJ01 à ADJSYM                         | 38      | Non publié |
| (f) Adjec                               | tifs non prédicatifs (simples)         |         |            |
| Laporte (2005)                          | ADJLOCTABLE                            | 1       | Revue      |
| Giry-Schneider (2005a)                  | DEDJA et DADJI                         | 2       | Revue      |
|   |  |         |            |

TABLE 5.1: Inventaire des tables du Lexique-Grammaire

lexicales.

Il faut en effet souligner la cohérence partielle de l'ensemble, malgré le nombre d'auteurs et la durée de construction. Citons par exemple les notations présentées en section 3.1, qui sont issues de conventions assez bien respectées par les différents auteurs. C'est une prouesse étant donné les habitudes individualistes des linguistes. Il n'existe aucune autre réalisation atteignant à la fois le même niveau de cohérence, la même couverture lexicale et la même couverture grammaticale.

Des travaux de mise en cohérence et d'explicitation des propriétés inventoriées dans les tables du Lexique-Grammaire ont été mis en place au LIGM, en ayant comme objectif de les rendre exploitables dans un analyseur syntaxique. Les méthodes adoptées afin de résoudre les problèmes qui se sont posés lors de cette étape d'homogénéisation des tables, constituent l'objet de ce chapitre.

#### 5.2 Format d'origine et classification

Dans cette section, nous expliquons en quoi le format sous forme de tables est plus lisible que d'autres, et pourquoi les intitulés de propriétés doivent être succincts et ne pas prendre la forme de structures de traits (5.2.1). Ensuite, nous précisons que chaque classe représente une sélection des entrées possédant un ensemble de *propriétés définitoires*, expression que nous définissons et illustrons à travers toutes ses représentations possibles (5.2.2). Lors de la délimitation des entrées lexicales, nous expliquons pourquoi les entrées sont séparées en cas de polysémie. De plus, nous présentons les tables qui présentent des doublons, correspondant à des descriptions croisées par différents auteurs (5.2.3). Enfin, nous listons les différentes versions existantes en détaillant le format Excel actuel, pour lequel il a fallu supprimer des cartouches horizontaux et numériser des tables de noms (5.2.4).

#### 5.2.1 Format tabulaire pour une meilleure lisibilité

Les tables ont été conçues pour être lisibles (Laporte, 2010), le but étant d'avoir un format facilement manipulable par des linguistes n'étant pas informaticiens. En effet, les entrées lexicales (en lignes) sont faciles à identifier visuellement et à comparer. De même, les propriétés syntaxico-sémantiques matérialisées verticalement (en colonnes) sont identifiées par les valeurs qu'elles prennent. Ces valeurs sont représentées par des étiquettes, ou intitulés, répétés sur chaque écran, et donc très succincts (chaque intitulé occupe au plus une trentaine de caractères). Ce format tabulaire permet de croiser sur un même écran des dizaines d'entrées avec des dizaines de propriétés. Ainsi, lorsque le linguiste code une entrée, il a sous les yeux la description d'entrées comparables, pour peu que chaque table regroupe une classe d'entrées suffisamment homogène. Cette visualisation facilite le codage, qu'il soit seul ou en groupe, et ce format favorise également l'échange entre les linguistes.

Chaque propriété syntaxico-sémantique décrit partiellement une construction. L'intitulé N0 être Vpp, dans la table 31H de BGL (pour toutes les tables de verbes distributionnels citées, se référer à la Tab. 5.1(a)), représente une phrase à interprétation statique constituée du sujet N0 de la construction de base, du verbe être et du participe passé du verbe. Dans le cas de l'entrée s'évanouir, dont la construction de base est illustrée par Luc s'évanouit, la construction à sens statique en question est celle de Luc est évanoui.

Pour que les intitulés de propriétés soient mnémoniques, ils ont été construits à partir de symboles représentant des valeurs de traits : N pour substantif ou argument syntaxique, être pour le verbe *être*, pp pour participe passé. Mais pour qu'ils soient succincts, on n'y a généralement pas précisé les traits correspondants, respectivement ici : catégorie grammaticale, verbe support, temps/mode.

Avant d'exploiter les tables du Lexique-Grammaire dans un système de TAL, il est important de s'assurer qu'il peut être achevé et mis à jour, et donc qu'il existe sous un format que l'on peut aisément lire et éditer. Pour certains (Gardent et al., 2005, 2006), le format des tables du Lexique-Grammaire n'est pas standard, car les constructions ne sont pas sous la forme de structures de traits, avec noms de traits et noms de valeurs, comme celles utilisées par les systèmes actuels. En adoptant de telles conventions, la propriété ci-dessus serait représentée par des formules telles que (Laporte, 2010) :

Ou, par des formules équivalentes en XML, encore moins concises, même si elles sont adaptées aux programmes informatiques :

```
</distribution>
  </constituent>
  </arguments>
</construction>
```

Les structures de traits sont un standard destiné à d'autres usages, incompatibles avec les exigences de compacité et de lisibilité de l'édition manuelle des tables. Les projets ComLex Syntax (Grishman et al., 1994) et FrameNet (Baker et al., 1998) n'ont également pas adopté un format de structures de traits pour l'édition et la mise à jour des lexiques. Or, ce sont les projets producteurs de lexiques à grande couverture pour le TAL, tels que la construction des tables du Lexique-Grammaire, qui ont vocation à nourrir la construction des standards et des normes. C'est le sens de la réflexion sur le format des tables du Lexique-Grammaire effectuée par le projet Genelex (Alcouffe et al., 1993), qui fut une des sources du projet de normalisation Eagles <sup>4</sup>. Le projet LexSynt <sup>5</sup> a également donné l'occasion de tenir compte des tables du Lexique-Grammaire lors de l'élaboration de la norme LMF (Francopoulo et al., 2006).

#### 5.2.2 Découpage en classes

Nous définissons les *propriétés définitoires*, en les illustrant à travers toutes leurs représentations possibles : constructions de base, propriétés distributionnelles, autres constructions, etc. Puis, nous introduisons ce que l'on appelle les *formules définitoires*, qui permettent de justifier la classification, avant d'expliquer les motivations et les problèmes de ce découpage.

#### Propriétés définitoires

Les tables du Lexique-Grammaire répartissent les entrées lexicales dans des classes. Chaque classe regroupe un certain nombre d'entrées jugées similaires, car elles acceptent des propriétés syntaxico-sémantiques communes, que l'on appelle les propriétés définitoires <sup>6</sup>. Les propriétés définitoires de ces classes relèvent généralement du cadre de sous-catégorisation. Ainsi, les critères les plus communément utilisés dans les propriétés définitoires sont le nombre de compléments, la nature prépositionnelle ou non des compléments (pour les compléments prépositionnels, sont distingués ceux qui sont introduits par les prépositions à, de, avec, Loc, etc.), la catégorie grammaticale du sujet et des compléments (sont distinguées les réalisations sous forme de complétive, notée Qu P, d'infinitive, notée V-inf W, et de syntagme nominal, notée N suivi d'un trait sémantique, comme par exemple, Nhum ou N-hum).

Par exemple, la table 9 de M. Gross a parmi ses propriétés définitoires : N0 V N1 à N2 (dans cette construction, N0 représente le sujet, V le verbe, N1 le premier argument, N2

<sup>4.</sup> http://www.ilc.cnr.it/EAGLES/home.html

<sup>5.</sup> http://lexsynt.inria.fr/index.php

<sup>6.</sup> Notons que le terme de propriété définitoire a été préféré à celui de *propriété définitionnelle*, mais ils sont tous les deux employés dans la littérature de manière équivalente.

le deuxième), où le complément essentiel direct N1 peut être occupé par une complétive : cette table regroupe des verbes comme dire, dissimuler et ordonner, dont le cadre de sous-catégorisation peut se caractériser par une complétive objet et un complément nominal introduit par la préposition à (Luc a (dit+dissimulé+ordonné) à Marie que Zoé chante). On peut remarquer que à N2 apparaît avant N1, en accord avec le fait que les propriétés définitoires n'imposent pas d'ordre sur les compléments. Le fait que l'argument N1 puisse être une complétive est codé dans la table pour différencier les complétives à l'indicatif (N1 =: Qu Pind), au subjonctif (N1 =: Qu Psubj) et celles qui sont interrogatives (N1 =: si P ou si P), et pour permettre également de reconnaître d'autres catégories grammaticales (voir 6.1.3).

La table 5 de M. Gross a parmi ses propriétés définitoires : N0 V Prép N1, mais aussi N0 =: Qu P, ce qui signifie que le sujet peut être occupé par une complétive. Ici c'est la préposition qui est codée dans la table, car elle varie en fonction des entrées (Qu'Ida allait partir cheminait dans sa tête / Que Max s'est enfui circule sur son compte). Le cadre de sous-catégorisation est donc défini par une complétive sujet et un complément nominal introduit par la préposition spécifiée dans la table.

La table 37M1 de BGL, a parmi ses propriétés définitoires : N0 V N1 Prép N2 et Prép2 =: de <sup>7</sup>. Contrairement à la table 5, toutes les entrées acceptent la préposition de pour l'argument N2 (Max abrutit ses élèves de travail / On a doté l'hôpital de scanners), mais aussi d'autres prépositions qui sont codées dans la table (Max abrutit ses élèves avec du travail / On a doté l'hôpital en scanners). La table 9 n'accepte que la préposition à pour l'argument N1, c'est pourquoi la propriété définitoire N0 V N1 à N2 suffit ici pour préciser à la fois la préposition et le nombre d'arguments. Le cadre de sous-catégorisation pour la table 37M1 est un complément nominal objet et un complément nominal introduit par la préposition de, mais aussi avec ou en, etc., selon les entrées.

Les propriétés définitoires sont constituées d'au moins une construction, dite construction de base. Ainsi, N0 V N1 à N2 est la construction de base de la table 9, alors que N0 V Prép N1 est celle de la table 5 et enfin, N0 V N1 Prép N2 celle de la table 37M1. La propriété N0 =: Qu P définitoire de la table 5 est une propriété distributionnelle, qui spécifie la catégorie grammaticale de l'argument N0, déjà défini dans une construction, souvent la construction de base. La propriété Prép2 =: de est également une propriété distributionnelle, définitoire de la table 37M1, qui spécifie la valeur de la préposition 8.

Une propriété définitoire peut aussi indiquer qu'un élément de la table entre dans deux constructions, qui sont généralement reliées par un lien de paraphrase. Cette deuxième construction est appelée propriété transformationnelle, car elle est déductible de la première par une redistribution, la première étant la construction de base. Ainsi la table 35S regroupe les verbes intransitifs symétriques qui se caractérisent par la construc-

<sup>7.</sup> Remarquons que Prép2 fait référence à la préposition du deuxième complément, même si elle n'est pas numérotée dans la construction.

<sup>8.</sup> Remarquons que la construction de base de la table 9 pourrait être également N0 V N1 Prép N2, avec Prép2 =: à définitoire, mais l'on a préféré intégrer la préposition dans la construction de base lorsqu'une seule était possible.

tion de base N0 V Prép N1 et par la deuxième construction définitoire N0 et N1 V (*Luc flirte avec Zoé / Luc et Zoé flirtent (ensemble)*).

Enfin, de nombreuses propriétés définitoires incluent des traits sémantiques élémentaires. Par exemple, des informations sur les classes des noms têtes des syntagmes nominaux (humain, concret, pluriel, etc.) : ainsi, la table 31H admet la propriété distributionnelle N0 =: Nhum indiquant que le sujet N0 de la construction de base doit être occupé par un groupe nominal dénotant une entité humaine (*Luc s'évanouit*).

Ou encore, des informations sur la sémantique des procès : ainsi les verbes entrant dans la construction N0 V N1 Prép N2, avec Prép =: de et dont le N1 dénote soit un lieu par rapport auquel est située l'entité à laquelle réfère N2, soit le bénéficiaire ou le détrimentaire du procès, ont été divisés en deux ensembles : la table 37E de M. Gross regroupe les procès d'enlèvement (Luc a débarrassé le grenier de ses caisses, exprimant l'acte d'enlever les caisses), tandis que les tables 37M1 à 37M6 de M. Gross regroupent les procès d'ajout (Luc a muni la porte d'un verrou, exprimant l'acte de mettre un verrou) 9. Les tables 37M1 à 37M6 se distinguent par des propriétés très diverses (morphologiques, sémantiques ou autres) qui ne relèvent pas du cadre de sous-catégorisation et qui auraient pu figurer en colonne dans une unique table 37M. La raison de ce découpage est principalement numérique : la table 37M aurait regroupé 890 verbes, et il a été considéré que la consultation manuelle d'une matrice de 890 lignes était laborieuse, d'où sa division en six sous-tables (voir 6.2.2).

Dans tous les cas cités précédemment, les propriétés définitoires correspondent à des propriétés qui sont vraies pour toutes les entrées d'une table, mais l'inverse est possible également, à savoir des propriétés interdites pour l'ensemble des entrées d'une table.

Reprenons, par exemple, la table 9 qui a comme construction de base N0 V N1 à N2, avec une complétive en N1. Il faut exclure la possibilité d'une complétive en N2, sinon cela inclurait la table 16 par exemple, qui a comme construction de base N0 V Prép N1 Prép N2, avec une complétive en N1 et en N2.

De même, la délimitation de la table 37M1 (N0 V N1 Prép N2, avec Prép =: de) inclut la négation de propriétés de complétives, sinon par exemple une partie de la table 10, qui a comme construction de base N0 V N1 Prép N2, avec une complétive en N1 (Le maire requiert du préfet que la police intervienne), se trouve incluse dans la table 37M1.

C'est le cas également de la table 32NM qui n'accepte pas la redistribution passive (Cette valise pèse 10 kilos / \*10 kilos sont pesés par cette valise). Par exemple, on peut interdire les propriétés [passif par] et [passif de], utilisées selon que le complément d'agent est introduit par la préposition par ou de, et qui indiquent que tous les autres objets sont conservés au passif. Ces deux propriétés font partie des propriétés transformationnelles, puisque ce sont des redistributions à partir de construction de base.

Enfin, nous pouvons voir le cas de la table 32H, qui a la propriété distributionnelle N1 =: Nhum obligatoire, ce qui signifie que N1 =: Nhum est toujours vraie alors que N1 =: N-hum n'est jamais acceptée.

<sup>9.</sup> Ceci est représenté par les deux propriétés définitoires N0 V N1 de N2 = N0 enlever N2 de N1 et N0 V N1 de N2 = N0 mettre N2 Loc N1, comme nous le détaillerons en 6.2.2.

#### Formules définitoires

Si l'on reprend à nouveau la table 9, la possibilité d'avoir une complétive en N1 est codée dans la table par les trois colonnes N1 =: Qu Pind, N1 =: Qu Psubj et N1 =: si P ou si P. La disjonction de ces trois propriétés fait donc partie de la définition de la table. Cela signifie qu'il faut prendre en compte cet ensemble de propriétés séparées par des ou logiques, c'est-à-dire dont au moins une des propriétés parmi l'ensemble est vraie. Cela correspond pour la table 9, si l'on écrit formellement cet ensemble, à la formule booléenne suivante : (N1 =: Qu Pind) ou (N1 =: Qu Psubj) ou (N1 =: si P ou si P).

De même, si l'on définit la possibilité d'avoir une complétive en N2 par les deux propriétés N2 =: Qu Pind et N2 =: Qu Psubj, l'exclusion de cette possibilité est représentée par les deux négations de propriétés non (N2 =: Qu Pind) et non (N2 =: Qu Psubj). La conjonction de ces deux négations de propriétés fait également partie de la définition de la table et peut être définie comme suit : non (N2 =: Qu Pind) et non (N2 =: Qu Psubj).

Nous pouvons ainsi définir formellement la délimitation d'une table par une formule définitoire, composée d'un ensemble de disjonctions, conjonctions et négations de propriétés, autrement dit, un ensemble de propriétés séparées par des ou logiques, des et logiques et des négations non. Elle y inclut aussi bien les propriétés définitoires vraies que fausses (introduites par la négation non) pour l'ensemble d'une table, ainsi que les disjonctions de propriétés codées dans la table (ensemble de propriétés séparées par des ou logiques). À titre d'exemple, reprenons l'ensemble des propriétés que l'on vient de citer pour la table 9 :

- sa construction de base est N0 V N1 à N2;
- l'exclusion de la possibilité d'avoir d'une complétive en N2 s'écrit :
  - non (N2 =: Qu Pind) et non (N2 =: Qu Psubj);
- la possibilité d'avoir une complétive en N1 s'écrit :

```
(N1 =: Qu Pind) ou (N1 =: Qu Psubj) ou (N1 =: si P ou si P)
```

On peut écrire formellement la définition de la table 9 (incomplète ici) par la conjonction de ces trois ensembles, ce qui donne la formule définitoire suivante :

```
(N0 V N1 à N2)
et non (N2 =: Qu Pind) et non (N2 =: Qu Psubj)
et ((N1 =: Qu Pind) ou (N1 =: Qu Psubj) ou (N1 =: si P ou si P)).
```

Ce sont ces formules définitoires qui permettent de délimiter les différentes classes et d'avoir donc des classes disjointes. Elles ont été formalisées pour toutes les tables de verbes distributionnels <sup>10</sup>, ce qui a permis de classer les tables selon un ordre de priorité à appliquer afin de savoir dans quelle table est incluse (ou doit être ajoutée) une entrée. L'ordre de priorité dans ce classement des verbes accompagné des formules définitoires de chaque table est inclus dans la version 3.3 et dans l'annexe F. Afin de pouvoir appliquer plus facilement cet ordre de priorité, nous avons créé un arbre de classement des verbes distributionnels, servant à déterminer à quelle classe appartient une entrée verbale donnée. Il est conçu pour un utilisateur qui connaît les propriétés de l'entrée et qui applique successivement les critères indiqués dans l'arbre. Il est inclus dans la version 3.3 et dans l'annexe G, accompagné d'une documentation expliquant les conven-

<sup>10.</sup> Nous avons réalisé ce travail en collaboration avec Eric Laporte et Christian Leclère en 2010-2011.

tions de lecture. Dans toute la suite, nous mettrons l'accent sur les propriétés définitoires vraies pour toutes les entrées d'une table, sans donner les formules définitoires.

#### Motivations et problèmes du découpage

Ceci nous amène à remarquer que ce découpage en classes, autrement dit le regroupement de certaines entrées, est en partie arbitraire. En effet, il est possible de prendre en compte des propriétés plus ou moins précises, qui englobent plus ou moins de verbes, et d'obtenir alors un nombre de classes différent. Par exemple, la construction N0hum V à N1 (qui revient à accepter la construction N0 V à N1 et la propriété distributionnelle N0 =: Nhum en même temps) concerne moins d'entrées que la construction N0 V à N1 sans restriction sur le sujet. De plus, d'autres propriétés auraient pu être prises en compte, ce qui aurait amené à un découpage totalement différent.

Mais ce qui importe, c'est le travail qui a été réalisé à partir de ce découpage. Nous aboutissons, au total, à 76 400 entrées prédicatives, qu'elles soient verbales, nominales, adjectivales ou adverbiales, mais également simples ou figées <sup>11</sup>, classées selon les critères choisis. Cela constitue une très grande base de données lexicales, comparée aux autres lexiques, présentés en 2.2.2, qui ont en moyenne moins de 10 000 entrées prédicatives.

Cependant, les propriétés définitoires vraies pour toutes les entrées d'une table ne figurent pas dans les tables : ainsi, la construction de base de la table 9 est N0 V N1 à N2, mais la table n'a pas de colonne intitulée N0 V N1 à N2, car c'est une information implicite qui est uniquement décrite dans la littérature. Or, cette propriété sert de référence pour la représentation des autres constructions, comme la propriété transformationnelle N0 V à N2 (effacement du N1 : Luc téléphone à tout le monde), et pour les propriétés distributionnelles, comme N0 =: N-hum (sujet de type non humain : Le chemisier blouse).

Citons R. Vivès, qui résume bien la préoccupation qui à cette époque était liée à la taille des données (Vivès, 1983) : «Dans les tables que nous avons établies, nous avons cherché à fournir les indications les plus significatives en essayant de limiter le nombre des colonnes. Lorsqu'une propriété est générale ou quasi-générale pour l'ensemble de la table, nous ne l'avons pas représentée, nous contentant de la signaler dans les commentaires consacrés à chaque table. Lorsqu'une propriété n'est vérifiée que par un nombre réduit d'éléments dans une table, nous avons adopté la même solution : cette propriété fait l'objet d'un commentaire.»

Nous nous sommes donc référée aux commentaires de chaque table dans la littérature, afin d'ajouter toutes les propriétés définitoires vraies pour toutes les entrées d'une table (voir section 5.4).

#### 5.2.3 Délimitation des entrées lexicales

Comme pour tout lexique au sens linguistique du terme, les objets de base des tables du Lexique-Grammaire sont les entrées lexicales. En cas de polysémie, les entrées sont

<sup>11.</sup> Sans compter les entrées adjectivales simples.

séparées : les entrées de foncer dans Luc fonce au port (reconnu par la construction de base N0 V Loc N1 de la table 2 de M. Gross) et dans Le pigment fonce les couleurs (décrit dans la table 37M4 avec la propriété N0 V N1 codée +) sont distinguées l'une de l'autre, de la même façon que foncer l'est de fonder dans Luc fonde une agence (reconnu par la construction de base N0 V N1 de la table 32A de BGL). Plusieurs constructions peuvent relever d'une même entrée. Ainsi, les tables du Lexique-Grammaire n'ont pas une entrée distincte pour Les couleurs foncent : il rattache cette construction à la même entrée que Le pigment fonce les couleurs, à travers la propriété N1 V W dans la même table 37M4.

Certaines classes font exception à ce principe. Ainsi, Paul barbouille de la peinture sur le mur est décrit dans la classe 38LD de BGL avec la construction de base N0 V N1 Loc N2 destination, où Loc désigne une préposition locative et l'objet locatif est interprété comme lieu de destination. La construction croisée (Paul barbouille le mur de peinture) est spécifiée dans cette entrée sous l'intitulé N0 V N2 (E+de N1), mais elle est également décrite indépendamment, de façon plus détaillée, dans la classe 37M6 (qui a pour construction de base N0 V N1 Prép N2 avec Prép2 =: de), avec une nouvelle numérotation. Il est prévu de rendre ces tables homogènes avec les autres sur ce point (Laporte, 2010).

De plus, le choix des propriétés définitoires a été fait individuellement par chaque auteur des tables du Lexique-Grammaire afin de correspondre à la thématique étudiée, sans forcément prendre en compte les autres travaux déjà réalisés, ou au contraire, en les incluant dans leur travail pour pousser plus loin leur description. Cela a conduit à ce que plusieurs entrées de même sens se retrouvent en doublons dans différentes classes, même si cela représente un cas minoritaire. Par exemple, pour les noms (cf. Tab. 5.1(b)), les tables FR1 à FR3 de G. Gross contiennent des doublons avec les tables de J. Giry-Schneider, ainsi que la table AA de G. Gross avec les tables d'A. Meunier (cela sera vu en détail en 6.3.3). Pour les expressions figées (cf. Tab. 5.1(c)), les entrées des tables de L. Danlos ont été pour la plupart reprises dans les tables de M. Gross, mais cela reste à vérifier. En ce qui concerne les verbes distributionnels (cf. Tab. 5.1(a)), certaines tables de BGL reprennent parfois des entrées déjà présentes dans les tables de M. Gross.

Ces entrées identiques sont donc considérées comme ayant deux sens distincts, puisqu'un même mot a autant d'entrées que de sens différents, alors que cela n'est pas le cas ici. Il faudrait donc fusionner les entrées redondantes, pour ne les faire figurer que dans une seule classe.

#### 5.2.4 Format des tables

Le format Excel est celui utilisé pour l'édition des tables car il assure une stabilité aux tables dans le temps, puisqu'il permet de représenter les tables indépendamment du logiciel utilisé <sup>12</sup>. Dans un premier temps, nous avons cherché à obtenir toutes les tables au format électronique, puisque certaines tables étaient seulement disponibles dans la

<sup>12.</sup> Microsoft Excel ou des logiciels libres équivalents, tels que OpenOffice.org Calc, qui est téléchargeable sur le site http://www.openoffice.org/.

littérature (dans l'annexe d'ouvrages ou de thèses), c'est-à-dire en version 1. En effet, il existe plusieurs versions des tables que nous détaillons. Puis, nous expliquons pourquoi nous avons supprimé les cartouches horizontaux lors du passage au format Excel. Enfin, nous nous penchons sur le cas des tables que nous avons dû numériser et modifier, pour les rendre conformes aux autres tables.

#### Versions des tables

La version 1 est celle d'origine, c'est-à-dire celle qui figure sous format papier dans la littérature, mais qui existait également à l'époque sous format électronique, dans des cartes perforées (deux par table, l'une contenant les intitulés des propriétés et l'autre les entrées avec leur codage), en ce qui concerne les tables les plus anciennes. Au fil du temps, les tables ont subi divers changements de support électronique (cartes perforées, bandes magnétiques, disquettes) et de format (au fur et à mesure que les outils pour les éditer ont évolué) <sup>13</sup>. Certaines ont été perdues par manque d'intérêt de la part des auteurs, des institutions, ou de la communauté scientifique.

La version 2 représente 60% des tables informatisées qui ont été mises en ligne en 2002 par Nathalie Bely sur le site http://infolingu.univ-mlv.fr/ (Données Linguistiques > Lexique-Grammaire > Visualisation). Un système a été mis en place, permettant d'effectuer une recherche par verbe et par table, avec la possibilité d'afficher les exemples des verbes sélectionnées dans les tables sélectionnées. De plus, un téléchargement est possible en XML, et une documentation est associée à chaque table. Cette documentation indique les propriétés définitoires et donne des exemples pour une entrée lexicale afin d'illustrer les différentes propriétés.

Les récentes modifications ont donné jour à la version 3 en septembre 2008, également téléchargeable sur ce même site (Données Linguistiques > Lexique-Grammaire > Téléchargement), qui est régulièrement actualisée. La version 3.3 (31 mars 2011) contient la totalité des tables dans toutes les catégories, sous tous les formats disponibles (cf. chapitre 9). La version 3.3 contient de plus une documentation exhaustive sur toutes les propriétés syntaxico-sémantiques des verbes, ainsi que la définition formelle de chaque table et l'ordre de priorité dans le classement des verbes.

#### Suppression des cartouches horizontaux

Dans la version 1, des *cartouches* horizontaux matérialisent une classification des propriétés, autrement dit, certaines propriétés sont regroupées en familles, voire mises en dépendance les unes par rapport aux autres, comme illustré à la Fig. 5.1 (Boons *et al.*,

<sup>13.</sup> De même qu'avec les cartes perforées, deux fichiers au format texte permettaient de représenter une table, grâce au programme d'édition d'A. Guillet (nommé EDIX et enregistré sur deux disquettes MS-Dos) qui présentait tout dans le bon ordre. Chaque intitulé de propriété était sur une ligne dans le premier fichier et le programme les écrivait de telle sorte qu'on pouvait lire les intitulés en colonne. Le deuxième fichier contenait en ligne le numéro de la ligne, l'entrée, une barre oblique et une série de + ou - dans l'ordre par rapport aux intitulés énumérés dans le premier fichier. Voici par exemple, une ligne de la table 31H: 7 s'agiter/- - + - + + + +).

1976b) <sup>14</sup>. On voit, en effet, que les six premières colonnes sont des propriétés distributionnelles de l'argument N0, comme l'indique le cartouche horizontal intitulé N0. De plus, l'intitulé N0 =: Npc (où Npc dénote le corps ou une partie du corps d'une personne) dépend de l'intitulé N0 =: Nhum, ce qui est représenté par le deuxième cartouche vertical inclus dans le premier.

Cette structuration n'est pas exploitable informatiquement de façon simple, car les intitulés de colonnes deviennent des objets complexes constitués de plusieurs étiquettes. De plus, même si le format Excel permet de garder les cartouches horizontaux grâce à des fusions de colonnes, ceci n'est pas conforme avec la contrainte d'avoir tous les intitulés sur la première ligne permettant d'utiliser les tables avec le logiciel Unitex (Paumier, 2003). Cette contrainte est d'autant plus valable aujourd'hui avec l'utilisation de l'outil LGExtract 15, qui permet de générer un lexique syntaxique pour le TAL, le lexique LGLex, à partir des tables du Lexique-Grammaire. Les cartouches horizontaux de la version 1 ont donc été supprimés, bien qu'ils aient contribué à la lisibilité tout en apportant des informations 16. Lors de la suppression de ces cartouches et de leurs dépendances 17, les informations qu'ils contenaient ont été incorporées aux intitulés.

| N <sub>0</sub> = N hum | $N_0 = N$ pc | $N_0 = N - hum$ | = N nr | $N_0 = V \Omega$ | $N_0 = V-n$ |             | No est V-ant | No est V pp | pc lui | > | il V No Ω |
|------------------------|--------------|-----------------|--------|------------------|-------------|-------------|--------------|-------------|--------|---|-----------|
| -                      | +            | +               | -      | -                | -           | croupir     | +            | +           | -      | - | +         |
| -                      | -            | +               | -      | -                | -           | croustiller | +            | -           | +      | - | +         |
| -                      | -            | +               | -      | -                | -           | cuver       | -            | +           | -      | - | +         |

FIGURE 5.1: Extrait de la table 31R des verbes distributionnels (version 1)

Un exemple est la table 36DT (version 1) (Guillet et Leclère, 1992), qui contenait l'intitulé Ppv =: lui dépendant de la colonne N2 =: N-hum. Il a été renommé Prép N2-hum = Ppv =: lui, la construction de base étant N0 V N1 Prép N2 (voir 6.2.2).

Un autre exemple est la table 34L0 (version 1) (Boons *et al.*, 1976b), où la numérotation des arguments de la moitié des constructions est indépendante de celle de la construction de base, et où deux cartouches horizontaux intitulés Standard et Croisée

<sup>14.</sup> La section 9.3 montre le même extrait de la table 31R sous tous les formats disponibles actuellement

<sup>15.</sup> LGExtract est relié à une table globale dans laquelle nous avons ajouté les propriétés manquantes et un unique script d'extraction incluant toutes les opérations liées à chaque propriété devant être effectuées pour toutes les tables (voir chapitre 7).

<sup>16.</sup> Ce travail a été réalisé par Eric Laporte en 2003-2004 (Laporte, 2010). Nous avons reproduit le même travail en 2009 pour les nouvelles tables de noms numérisées (voir plus loin), ainsi que les nouvelles tables d'expressions figées numérisées (voir 6.4.4).

<sup>17.</sup> Les dépendances ne pouvant figurer dans le format Excel.

lèvent l'ambiguïté informellement. Ils correspondent respectivement à la construction de base N0 V Loc N1 (ou construction standard) et à la propriété transformationnelle N1 V de N0 (ou construction croisée), mais les propriétés associées à chaque cartouche sont toutes numérotées à partir de 0. On a donc un ensemble de constructions presque identiques sous chacun des 2 cartouches : par exemple, la propriété N0 est V-ant Prép N1 est codée deux fois, elle correspond à La lumière est clignotante dans le salon pour la construction standard, et à La rue est clignotante de mille lumières pour la construction croisée. Lors de l'élimination des cartouches horizontaux, les propriétés dépendantes du cartouche intitulé Croisée ont été renommées, en modifiant la numérotation de l'argument N0 (remplacé par N1) : par exemple, la propriété précédente a été renommée en N0 être V-ant Loc N1 pour la construction standard, et N1 être V-ant Prép N0 pour la construction croisée.

Ces conventions semblent avoir compliqué la compréhension des propriétés de certains utilisateurs. Ainsi, dans Gardent et al. (2005), on se demande si les indices (d'un argument dans une construction ou dans une propriété distributionnelle) font référence à la position du constituant dans la construction de base ou dans une autre.

Prenons le cas de la table 32PL de BGL pour expliquer ce problème : cette table a pour construction de base N0 V N1, mais dès la deuxième colonne codée dans la table, un argument numéroté N2 apparaît, par exemple dans l'intitulé N2 V N1. On ne peut pas relier cette redistribution à la construction de base, mais on peut la relier à une autre construction codée dans la table quelques colonnes après, intitulée N0 V N1 en N2. Il faut donc considérer la table dans son ensemble pour donner un sens à chaque constituant. Tous les intitulés étant à présent homogènes, les numéros d'ordre des constituants figurant dans les propriétés soit font référence à ceux figurant dans la construction de base, soit ce sont des arguments supplémentaires. Dans ce cas, ils font référence à une autre construction les contenant qui est plus longue que la construction de base. Informatiquement, cela ne pose pas de problème si l'on essaye toujours de se référer à la construction la plus longue. Ce point sera étudié plus en détail au chapitre 8.

#### Tables numérisées

Certaines tables de noms n'étaient disponibles qu'en version 1, nous les avons scannées et leur avons appliqué un outil de reconnaissance optique de caractères (OCR) <sup>18</sup>, ce qui a ensuite nécessité un travail de correction manuelle.

Tout d'abord, une grande partie des entrées étaient en majuscules (par exemple, les tables ANA à ANS), il a donc fallu tout réécrire en minuscules, en ajoutant tous les accents car ils n'étaient pas présents. De plus, quelques fautes d'orthographe étaient déjà présentes dans les tables d'origine (comme par exemple pour la table SYM, les entrées INTERVENTIR, JUMULER et RACCOM, qui ont été corrigées en intervertir, jumeler et raccommoder). D'autres fautes sont apparues lors de la numérisation, car certains caractères étaient moins bien imprimés que d'autres, notamment des fautes d'accents

<sup>18.</sup> Nous avons réalisé ce travail en collaboration avec Jean-Pierre Heymann en 2009.

(comme complicite et mëpris, corrigés en complicité et mépris dans la table APE21) et quelques lettres mal reconnues (accrOissement, équilibre et rietus, corrigés en accroissement, équilibre et rietus dans la table APP1) <sup>19</sup>.

Ensuite, les cartouches horizontaux ont été éliminés lors de la correction manuelle. On a donc minutieusement renommé toutes les colonnes concernées pour rendre les intitulés conformes aux conventions des autres tables, ou identiques à ceux existants déjà lorsque leur définition correspondait, afin de former un tout cohérent. Par exemple, pour les tables APE1 à APE3, les 2 cartouches intitulés AVOIR et PERDRE englobaient chacun un ensemble de propriétés définissant la nature du déterminant. Prenons par exemple la propriété distributionnelle Det =: un, qui était présente à l'identique sous les 2 cartouches : elle a été remplacée par Det =: un, Vsup =: avoir et Det =: un, Vsup =: perdre pour spécifier avec quel verbe support se combine chaque déterminant codé.

Cela a permis d'avoir 16 tables de noms supplémentaires : les tables de D. de Négroni, R. Vivès et J. Labelle (cf. Tab. 5.1(b)). Leur description est faite en 6.3.4. La même chose a été faite pour certaines tables d'expressions figées : Z5D, Z5P, Z1, ZS et ZP de L. Danlos (cf. Tab. 5.1(c)). Nous étudierons cela en détail en 6.4.4.

# 5.3 Formalisation et homogénéisation des propriétés syntaxico-sémantiques

Après avoir défini les entrées et les propriétés définitoires, nous illustrons les propriétés syntaxico-sémantiques qui sont codées pour chaque entrée, en listant les différentes possibilités de représentation (5.3.1). Puis, nous montrons comment nous avons rendu toutes les propriétés homogènes et plus précises (5.3.2). Enfin, nous traitons de la création de la documentation complète de toutes les propriétés des verbes, ce qui a permis de les définir clairement (5.3.3).

# 5.3.1 Représentation des propriétés

Les tables se présentent sous forme de matrices de + et de - dans lesquelles les colonnes indiquent les propriétés syntaxico-sémantiques qui varient d'un élément à l'autre. Pour chaque entrée d'une table, les colonnes indiquent :

- les éléments morphologiques constitutifs de l'entrée décrite (c'est-à-dire, les pronoms clitiques figés avec le verbe : Ppv =: se figé, Ppv =: y figé, etc.);
- les constructions additionnelles à la construction de base;
- les propriétés distributionnelles des arguments (catégorie grammaticale : N0 =: Qu P, valeur de la préposition : Prép2 =: de, trait sémantique : N1 =: Nhum, etc.);
- les propriétés transformationnelles (redistribution : [passif par], pronominalisation :
   Ppv =: y, etc.).

<sup>19.</sup> Notons que nous avons également corrigé les fautes d'orthographe des tables AD à IS2 de G. Gross qui étaient déjà en version Excel.

Ainsi, dans la table 9, une colonne intitulée Qu Psubj = de V2-inf W permet de coder si un verbe appartenant à cette table autorise que son complément direct (de position 1, comme l'indique la colonne N1 =: Qu Psubj) soit une infinitive introduite par la préposition de et contrôlée par N2 (Luc a (ordonné+dit) à Zoé de chanter, à contraster avec \*Luc a dissimulé à Zoé de chanter). Rappelons que la construction de base de la table 9 est N0 V N1 à N2, qui accompagnée de la colonne N1 =: Qu Psubj et Qu Psubj = de V2-inf W revient à admettre la construction N0 V de V2-inf W à N2.

Une autre colonne intitulée Qu P = Aux V0-inf W permet de coder si un verbe appartenant à la table 9 autorise que son complément direct (comme l'indique N1 =: Qu Pind) soit une infinitive directe à un temps composé et contrôlée par le sujet N0 ( $Luc\ a\ (dit+dissimulé)$  à  $Zoé\ avoir\ chanté$ , à contraster avec \* $Luc\ a\ ordonné$  à  $Zoé\ avoir\ chanté$ ).

On a donc ici une structure hiérarchique implicite entre colonnes. En effet, la colonne Qu Psubj = de V2-inf W dépend d'une colonne qui indique que la complétive est au subjonctif ( $Luc\ a\ (dit+ordonn\acute{e})\ \grave{a}\ L\acute{e}a\ que\ Zo\acute{e}\ parte\ demain$ ) tandis que la colonne  $Qu\ P = Aux\ V0$ -inf W dépend d'une colonne qui indique que la complétive est  $\grave{a}$  l'indicatif ( $Luc\ a\ (dit+dissimul\acute{e})\ \grave{a}\ L\acute{e}a\ que\ Zo\acute{e}\ part\ demain$ ).

Une propriété peut également servir de renvoi à un emploi qui figure dans une autre table. Ainsi, comme nous l'avons déjà mentionné en 5.2.3, la construction N0 V N2 (E+de N1) dans la table à construction standard 38LD indique pour certains verbes l'existence d'une construction croisée correspondante, laquelle figure dans une autre table de type 37 (ayant comme propriétés définitoires N0 V N1 Prép N2 et Prép2 =: de):

Luc saupoudre du sel sur les frites (38LD) Luc saupoudre les frites de sel (37M4)

# 5.3.2 Propriétés homogènes et plus précises

Les propriétés syntaxico-sémantiques sont représentées par des intitulés succincts (cf. 5.2.1), moins précis que les formalismes utilisés par les analyseurs syntaxiques et les grammaires pour représenter les constructions syntaxiques. Par exemple, dans l'intitulé N0 V vers N, qui représente une construction illustrée par Des animaux divaguent vers le fleuve, le symbole N représente un groupe nominal, déterminant compris (par exemple, le fleuve). Dans l'intitulé N0 V N1 Dnum N, qui représente la construction de Luc loue son studio 400 euros, le même symbole N représente cette fois-ci un substantif, alors que le déterminant (ici 400) est symbolisé séparément par Dnum. Certaines informations sont donc implicites, non entièrement spécifiées ou représentées de façon non uniforme (Hathout et Namer, 1997).

Un travail systématique sur les intitulés de propriétés a été engagé au LIGM, afin d'élever légèrement leur degré de formalisation, sans toutefois en modifier substan-

tiellement les conventions d'origine, afin de garder leur compacité et leur lisibilité <sup>20</sup>. L'objectif est de rendre l'ensemble des classes cohérent.

Tout d'abord, certains intitulés de colonnes peuvent être différents d'une table à l'autre alors qu'ils dénotent la même propriété linguistique. Après les avoir repérés, nous avons choisi une notation commune et effectué les transformations nécessaires.

Certaines différences sont dues simplement à des erreurs d'inattention, ou à des détails qui n'ont pas été comparés à l'existant. C'est ainsi que l'intitulé Det =: E a été remplacé par Det =: <E> pour être identique aux autres tables de noms (cela concerne les tables ANO1, ANDN et F1A à F9, cf. Tab. 5.1(b)).

D'autre part, l'intitulé [extrap] présent dans les tables de M. Gross et l'intitulé il V N0 W utilisé par BGL ont la même signification (cf. Tab. 5.1(a)). Nous avons donc renommé les intitulés de toutes ces colonnes en [extrap].

Il fallait cependant veiller à ne pas abuser de ce type de regroupement pour ne pas perdre une information sous-jacente. Ainsi, les deux intitulés [passif par] et N1 être Vpp par N0 peuvent paraître identiques, alors qu'avec le premier les autres objets sont conservés, ce qui n'est pas le cas avec le deuxième. L'intitulé N1 être Vpp, désignant le passif sans compléments, est assez proche également de N1 être Vpp par N0, alors qu'il a la particularité d'être acceptable au présent et d'être interprété comme un résultat statique du procès.

De plus, certains intitulés de colonnes laissaient implicites des informations pourtant nécessaires à leur exploitation automatique. Ainsi, l'intitulé [pc z.] («Prép ce = zéro») signifie que la préposition et le ce de la complétive (s'il est présent) peuvent être effacés. Le problème est que cet intitulé ne précise pas quel est l'argument concerné par le fait de pouvoir prendre la forme Qu P, en plus de la forme Prép ce Qu P. Par exemple, dans la table 16 de M. Gross, les deux arguments sont des complétives (sa construction de base est N0 V Prép N1 Prép N2). Nous avons créé les intitulés Prép N1 =: Prép ce Qu P = Qu P et Prép N2 =: Prép ce Qu P = Qu P pour expliciter le fait que la propriété concerne l'argument N1 ou N2 <sup>21</sup>.

Les tables de verbes locatifs contenaient une colonne source/destination, qui ne tenait pas compte des différents arguments présents dans chaque table. C'est pourquoi elle a été remplacée par N0 V Loc N1 source Loc N2 destination pour la table 35L, par N0 V Loc N1 Loc N2 pour la table 35ST et par N0 V N1 Loc N2 source Loc N3 destination pour les tables 32PL, 38LH et 38LS <sup>22</sup>. Cette clarification a entraîné l'éclatement de ces tables (voir 6.2.3), afin de séparer celles contenant systématiquement deux arguments locatifs de celles n'en contenant qu'un seul.

Un dernier exemple, la propriété (N1)(de V1 W) codée dans la table 12 de M. Gross

<sup>20.</sup> En ce qui concerne les adverbes, nous avons de plus scindé deux ressources ne suivant pas les mêmes principes de représentation, ce qui sera détaillé en 6.5.1.

<sup>21.</sup> Nous avons réalisé ce travail en collaboration avec Eric Laporte en 2007-2008 (Tolone, 2009). Nous avons repris la même notation en 2009 pour les tables de noms ANA de J. Labelle, APE2, APE3 et APP2 de R. Vivès (cf. Tab. 5.1(b)).

<sup>22.</sup> Nous avons réalisé ce travail en collaboration avec Eric Laporte en 2008.

a été réintitulée Qu Psubj =: Qu Ni Vsubj W = (Ni) (de Vi-inf W). Cette propriété relie la construction illustrée par *Le ressort empêche la bague de glisser*, à celle de *Le ressort empêche que la bague glisse*. L'emploi du symbole N1 pour désigner le sujet qui subit la montée, ici *la bague*, était critiquable car ce symbole désigne déjà par ailleurs l'ensemble de la complétive objet, en l'occurrence *que la bague glisse*. C'est pourquoi il a été remplacé par Ni <sup>23</sup>.

De plus, certaines colonnes étaient restées sans intitulé:

- la table 39 de BGL (cf. Tab. 5.1(a)) possédait une colonne sans intitulé. Elle a été supprimée car un seul verbe était concerné et sa signification n'a pas pu être rétablie;
- la table 35RR de BGL (cf. Tab. 5.1(a)) n'était au départ qu'un projet de table initié par A. Guillet et douze intitulés de colonnes n'ont pas été retrouvés.
  Nous avons pu reconstituer la plupart des intitulés en partant du codage des entrées, sachant que la construction de base de la table 35RR est N0 V Prép N1 Prép N2 <sup>24</sup>. Les 2 premières colonnes ont été codées N0 =: Nhum et N0 =: N0-hum, les colonnes 5 et 6, N1 =: Nhum et N1 =: N0-hum et les colonnes 9 et 10, N2 =: Nhum et N2 =: N0-hum, ce qui semble assez cohérent puisque toutes les tables codent cette information. Les colonnes 7 et 12 ont été codées N1 = : le fait Qu P et N2 = : le fait Qu P et la colonne 11, N2 =: Dnum Nmes. La colonne 3 a été codée N0 et N2 V Prép N1 (Max conspire avec Luc contre le président = Max et Luc conspirent contre le président). En ce qui concerne les colonnes 4 et 8, plusieurs propositions ont été faites, mais sans faire l'unanimité, elles restent donc sans intitulé;
- quelques tables d'expressions figées sont également dans ce cas : E1HC (sept intitulés), E1 (trois intitulés), EAPC (deux intitulés), EPDETC (un intitulé). Elles ont été créées par M. Gross (cf. Tab. 5.1(c)), qui n'a pas eu le temps des les achever ni de les publier pour certaines, et il est difficile de retrouver les intitulés.

# 5.3.3 Documentation des propriétés

Les propriétés syntaxico-sémantiques ne sont pas définies avec précision par leurs intitulés. Elles sont documentées dans des publications scientifiques mais cela reste insuffisant :

- toutes ne sont pas documentées, comme c'est le cas pour certaines classes d'expressions figées de M. Gross (cf. Tab. 5.1(c)) qui n'ont même pas été publiées;
- leur documentation est parfois difficilement accessible, car certains ouvrages sont moins diffusés que d'autres. C'est le cas des rapports ou des thèses n'ayant pas débouché sur une publication : Boons et al. (1976a) pour les verbes, Meunier (1981) et Giry-Schneider et Balibar-Mrabti (1993) pour les noms prédicatifs;
- aucun ouvrage n'a été traduit en anglais;

<sup>23.</sup> Nous avons réalisé ce travail en collaboration avec Eric Laporte, Christian Leclère et Takuya Namakura en 2009 (Laporte, 2010).

<sup>24.</sup> Nous avons réalisé ce travail en collaboration avec Eric Laporte, Christian Leclère et Benoît Sagot en 2008.

- les définitions manquent de précisions pour les spécialistes d'analyse syntaxique, qui ne sont pas toujours des spécialistes de syntaxe;
- un même intitulé peut avoir différentes interprétations et représenter une propriété linguistique différente en fonction des classes; ainsi N0 =: N-hum indique que le sujet N0 de la construction de base peut être occupé par un groupe nominal dénotant une entité non humaine, le verbe conservant son sens canonique (cf. 5.2.2 avec Le chemisier blouse), sauf dans la classe 31H où ce même intitulé indique que la phrase prend alors un sens métaphorique, comme dans Le paysage sommeille, à contraster avec Luc sommeille;
- deux intitulés similaires peuvent avoir une signification différente dans deux tables distinctes, ou éventuellement dans une même table. Ainsi, la table 36DT comporte essentiellement des verbes prenant un objet direct non humain concret. La propriété N1 =: Nhum y a deux rôles : d'une part elle marque la possibilité pour certains verbes de produire des métaphores (Paul emprunte une secrétaire au patron, par rapport à Paul emprunte cent francs au patron); d'autre part, elle note une sous-classe particulière de constructions où l'objet échangé est strictement humain (Paul délègue sa secrétaire au patron). Ce dernier cas est séparé de l'autre par le codage de la colonne N1 =: N-hum.

L'interprétation de certains intitulés peut donc être difficile (Hathout et Namer, 1997). Pour remédier à ce problème, la documentation des propriétés la plus complète, qui est celle des verbes locatifs (Guillet et Leclère, 1992) (pp. 409-430) a été entièrement revue, étendue à toutes les propriétés des verbes distributionnels, et traduite en anglais <sup>25</sup>.

De plus, cela a permis de vérifier pour toutes les classes de verbes à quelle signification chaque intitulé faisait référence, l'objectif étant qu'un intitulé dénote une seule propriété linguistique, qui elle-même n'est désignée que par un seul intitulé dans l'ensemble des tables. Elle est à présent complète et mise à jour dès qu'une modification a lieu dans une table. Elle est incluse dans la version 3.3 et dans l'annexe E.

#### 5.4 Tables des classes

Comme nous l'avons évoqué en 5.2.2, les tables ne codent pas explicitement leurs propriétés définitoires. C'est un problème important pour leur exploitation automatique, puisque ces propriétés sont parmi les plus importantes. Les critères de découpage en classes et les propriétés définitoires ne sont décrites que dans la littérature associée aux tables. Ce constat a motivé depuis quelques années le développement au LIGM d'un nouveau type de tables, appelées tables des classes (Constant et Tolone, 2010).

La notion de table des classes a été définie suivant Paumier (2003) <sup>26</sup>. Son rôle est d'assigner des propriétés syntaxico-sémantiques à une classe quand cela est possible,

 $<sup>25.\,</sup>$  Nous avons réalisé ce travail en collaboration avec Eric Laporte et Christian Leclère en 2008-2011.

<sup>26.</sup> Elle était appelée au départ *super-table* et elle comportait quelques variantes puisque son objectif était de l'utiliser avec le logiciel Unitex afin de générer un graphe par table à partir d'un graphe générique faisant appel à cette super-table, puis de créer un graphe lexical pour chaque entrée à partir de ces graphes et des tables elles-mêmes.

c'est-à-dire, quand leur valeur est constante pour toute une classe (par exemple, les propriétés définitoires d'une classe).

Ces tables sont au nombre d'une par catégorie grammaticale, donc 4 au total : une pour les verbes, une pour les noms prédicatifs, une pour les expressions figées et une pour les adverbes (cf. Tab. 5.1). Une table des classes regroupe en lignes l'ensemble de toutes les propriétés syntaxico-sémantiques répertoriées pour la catégorie concernée, et liste en colonnes l'ensemble des classes définies pour cette même catégorie. À l'intersection d'une ligne et d'une colonne, le signe + (respectivement, -) indique que la propriété correspondante est vérifiée (respectivement, non vérifiée) par tous les éléments de la classe (c'est-à-dire par toutes les entrées de la table correspondante). Le signe o indique que la propriété est explicitement codée dans la table concernée, car elle est vérifiée par certaines de ses entrées mais pas toutes <sup>27</sup>. Le signe O indique que la propriété n'est pas codée dans la table concernée mais devrait l'être, car elle dépend des entrées. Enfin, le signe ? indique une cellule non encore renseignée.

Par exemple, la table des classes des verbes regroupe les 67 classes de verbes distributionnels et l'ensemble des 551 propriétés syntaxico-sémantiques. Un extrait de cette table est donné à la Fig.  $5.2^{28}$ . La notation  $V_{-}$  indique qu'il s'agit de classes de verbes. Dans cette table, on peut voir la construction de base de la classe 33 (cf. section 3.2): la construction  $N0 \ V$  à  $N1 \ est \ codée + \ car \ elle \ vaut + \ pour \ l'ensemble des entrées de la table 33; de même pour la classe 1, qui a la construction <math>N0 \ V \ Prép \ V0$ -inf  $W \ codée +$ .

Les propriétés distributionnelles N1 =: Nhum et N1 =: N-hum se voient assigner o pour la table 33 parce qu'elles dépendent des entrées lexicales. En revanche, pour la table 32H, la propriété distributionnelle N1 =: Nhum est codée + alors que la propriété distributionnelle N1 =: N-hum est codée - car l'objet est obligatoirement humain. Les deux propriétés distributionnelles sont donc définitoires de la table, la deuxième étant constante - pour la table.

Remarquons que le codage — dans la table des classes désigne réellement dans ce cas une propriété que n'accepte aucune des entrées. Dans d'autres cas, il peut désigner simplement une information non pertinente (par exemple, une propriété de N1 pour une entrée qui n'a pas de N1). Cela vient du fait que certaines propriétés sont spécifiques à une table donnée. Elles ne seraient pas pertinentes pour une autre; ainsi, N2 bénéficiaire ne figure qu'en 36DT. L'absence d'une propriété dans une table peut donc signifier qu'elle est constante + ou — pour toutes les entrées de cette table, ou qu'elle n'a pas été jugée intéressante, ou encore qu'elle n'est pas pertinente pour la table en question.

La table des classes fait apparaître les propriétés définitoires, toutes celles qui sont

<sup>27.</sup> Dans Paumier (2001), on faisait référence à la propriété codée dans la table par une variable : **@A** pour la première colonne contenant la première propriété à droite, **@B** pour la deuxième, etc. De plus, on pouvait utiliser la négation d'une propriété avec la variable !**@A** pour récupérer le codage inverse sans devoir créer une colonne le contenant.

<sup>28.</sup> La section 9.3 contient un autre extrait de cette même table des classes, avec l'ensemble des propriétés pertinentes pour la classe 31R, toutes ne figurant pas ici.

|                       |     |     |     | س     | <b>—</b> |    | - H   |
|-----------------------|-----|-----|-----|-------|----------|----|-------|
|                       |     | 2   | ⊣   | V_31R | 311      | 33 | 32F   |
| Propriété \ table     | V_1 | V_2 | V_4 | >     | V-31H    | >  | V_32H |
| N0 =: Nhum            | О   | +   | _   | О     | +        | О  | О     |
| N0 =: N-hum           | _   | _   | _   | О     | _        | О  | _     |
| N0 =: Nnc             | О   | _   | _   | _     | _        | _  | _     |
| N0 =: Nnr             | _   | _   | +   | _     | _        | О  | О     |
| N0 =: V1-inf W        | _   | _   | +   | _     | _        | _  | _     |
| <ent>V</ent>          | О   | О   | О   | О     | О        | О  | О     |
| Ppv =: se figé        | О   | О   | _   | О     | О        | О  | О     |
| N0 V                  | _   | _   | О   | +     | +        | О  | _     |
| N0 V N1               | _   | _   | +   | _     | _        | _  | +     |
| Prép1                 | О   | _   | _   | _     | _        | _  | _     |
| NO V à N1             | _   | _   | _   | _     | _        | +  | _     |
| N1 =: Nhum            | _   | _   | О   | _     | _        | О  | +     |
| N1 =: N-hum           | _   | +   | О   | _     | _        | О  | _     |
| N1 =: Qu P            | _   | _   | _   | _     | _        | _  | _     |
| N1 =: Qu Psubj        | _   | _   | _   | _     | _        | _  | _     |
| N0 V Prép N1 V0-inf W | _   | О   | _   | _     | _        | _  | _     |
| N0 V N1 V0-inf W      | _   | О   | _   | _     | _        | _  | _     |
| N0 V V0-inf W         | _   | +   | _   | _     | _        | _  | _     |
| N0 V Prép V0-inf      | +   | _   | _   | _     | _        | _  | _     |
| N0 V Prép Nhum        | О   | _   | _   | _     | _        | _  | _     |
| N0 V Prép N-hum       | О   |     | _   |       | _        | _  | _     |
| N0 V Nhum             | О   | _   | _   | _     | _        |    | _     |
| N0 V N-hum            | О   | _   | _   | _     | _        | _  | _     |

TABLE 5.2: Extrait de la table des classes des verbes distributionnels

constantes + ont été codées, comme nous le verrons en détail au chapitre 6. Notons que dès que l'on peut coder une information avec différentes combinaisons de propriétés, un choix arbitraire a été fait et les autres possibilités ont été codées — dans la table des classes pour ne pas engendrer de redondance. Par exemple, pour la table 9, la construction de base est N0 V N1 à N2, mais aurait pu également être N0 V N1 Prép N2 avec Prép2 =: à définitoire, mais l'on a préféré intégrer la préposition dans la construction de base lorsqu'une seule était possible. Les deux propriétés N0 V N1 Prép N2 et Prép2 =: à sont donc codées — dans la table des classes.

La table des classes permet également de coder toutes les propriétés syntaxicosémantiques pour chaque table, y compris celles dont on ne trouve la description que dans la littérature et qui de ce fait, ne sont pas exploitables alors qu'elles peuvent être pertinentes. C'est le cas, par exemple, des propriétés transformationnelles [passif par] et [passif de], qui sont fréquentes en français. Ces propriétés fondamentales ont en général été étudiées et décrites dans les thèses, ce qui signifie que lorsqu'elles ne sont pas codées dans une table, elles sont constante + ou - (avec peut-être quelques exceptions répertoriées dans les thèses), sans pour autant être définitoire puisqu'elles n'ont pas participées au découpage de la classe en question. Cet ensemble de propriétés est à coder prioritairement dans la table des classes, mais il n'est pas toujours facile à repérer.

En outre, le choix des propriétés codées dans chaque table ayant été arbitraire, certaines propriétés peuvent, après réflexion, se révéler pertinentes, soit constante + pour la table, soit variant selon les entrées. Dans ce dernier cas, cela signifie qu'il s'agit d'une propriété qui devrait être codée o dans la table des classes et codée dans la table. En attendant d'être effectivement codée dans la table, elle est codée O dans la table des classes.

La construction de ces tables des classes a permis une homogénéisation importante des tables et en particulier des intitulés de colonne. C'est ainsi que de nombreuses colonnes ont changé de nom (cf. 5.3.2), cela a permis également de revoir la notation des constructions de base de chaque table, ce qui sera détaillé au chapitre 6.

# 5.5 Codage des tables

Avant de détailler le codage restant à faire (5.5.2), nous abordons le problème des informations manquantes dans les tables (5.5.1). Ensuite, nous évoquons les difficultés que le codage peut poser (5.5.3).

# 5.5.1 Informations manquantes

Comme cela a été signalé dans Gardent et al. (2006), certaines informations sont incomplètes ou absentes des tables du Lexique-Grammaire, comme par exemple les fonctions grammaticales et les rôles thématiques remplis par chacun des arguments. Mais d'autres propriétés, qui ne sont généralement pas utilisées par les analyseurs, sont présentes, comme l'interprétation temporelle des infinitives, laquelle peut être utile à la construction d'une représentation du sens du texte.

Comme cela a été expliqué dans Laporte (2010), les fonctions grammaticales ne sont pas toutes codées, car elles recouvrent des propriétés syntaxico-sémantiques, généralement plus factuelles, avec lesquelles elles font en partie double emploi. Ainsi, la notion de complément d'objet direct se fonde sur différentes propriétés qui ne coïncident pas toujours : position après le verbe, absence de préposition, pronominalisation, passivation, etc. (Gross, 1969). Ce sont plutôt ces propriétés qui sont codées dans les tables du Lexique-Grammaire, ce qui a l'avantage d'être plus précis. En particulier, les auteurs des tables du Lexique-Grammaire des verbes distributionnels ont joué un rôle pionnier dans la délimitation entre les compléments essentiels (objets) et circonstanciels (adjoints, modifieurs). Ainsi, ils ont décrit comme complément essentiel le complément direct des verbes de la classe 32NM (Luc chausse une grande taille / La pièce sent le jasmin), souvent considéré comme circonstanciel. Il en est de même du complément indirect de nombreux verbes locatifs (Luc place sa voiture contre le mur, table 38LD). Ils ont également recensé de nombreux compléments qui ont un comportement intermédiaire entre ceux d'un complément essentiel et d'un complément circonstanciel, par exemple sur ce point dans Luc se ravise sur ce point (table 31H).

En ce qui concerne les rôles thématiques et plus généralement la formalisation du sens, les auteurs des tables du Lexique-Grammaire se sont limités à des phénomènes dont ils ont pu encadrer l'observation par des tests syntaxiques (voir 5.5.3).

# 5.5.2 Codage inachevé

Le codage des tables n'est pas terminé.

En effet, du côté des propriétés :

- les ? dans la table des classes correspondent pour la plupart à des propriétés non encore étudiées dans certaines tables. L'importance de certaines d'entre elles empêche l'analyse des constructions correspondantes par un analyseur;
- les constructions dont la formation est régulière, comme la négation ou les propositions relatives, ont été négligées, sauf lorsqu'elles varient en fonction des éléments lexicaux;
- certaines constructions, notamment pronominales, ne sont pas codées.

De même, du côté des entrées :

- certaines entrées dans les tables des verbes n'ont pas encore été codées et contiennent des signes ~ à la place des + et des −. Ces emplois de verbes ne seront pas pris en compte dans un analyseur, alors qu'ils sont parfois essentiels;
- d'autres entrées sont tout simplement manquantes tout n'ayant pas été encore étudié, surtout dans certaines catégories.

Ceci est le cas des adjectifs prédicatifs, pour lesquels un travail de découpage est en cours d'achèvement par J. Giry-Schneider (cf. Tab. 5.1(e)). Ce travail a permis d'établir 38 classes, mais il reste encore à coder un ensemble de propriétés syntaxico-sémantiques (à définir) pour les entrées retenues. Il faut toutefois remarquer que les tables Adj1 à Adj13 de L. Picabia existent en version 1, cependant leur découpage n'étant pas assez fin, il a été décidé par le LIGM qu'il était préférable d'en créer de nouvelles. Certains adjectifs non prédicatifs ont également donnés lieu à une étude par E. Laporte et J. Giry-Schneider

(cf. Tab. 5.1(f)), mais seulement trois tables existent au format Excel, dont deux doivent être fusionnées, c'est pourquoi elles ne sont pas prises en compte actuellement.

Ajoutons enfin que les 5 tables de noms FD1 à FD4 de L. Pivaut (cf. Tab. 5.1(b)) viennent d'être numérisées, ce qui demande un travail de correction manuelle avant d'envisager leur utilisation. De même, les 3 tables d'expressions figées ZD, ZM et Z de L. Danlos (cf. Tab. 5.1(c)) n'ont pas été numérisées car il existe une version plus récente et plus complète avec un découpage différent : 24 tables au lieu de 8, mais toutes n'ont pas été retrouvées (voir 6.4.4).

Toutes ces informations sont certainement indispensables au bon fonctionnement des analyseurs syntaxiques symboliques. Malgré ces limitations, il est difficile de contester la richesse des informations contenues dans les tables du Lexique-Grammaire, en comparaison avec d'autres lexiques structurés. Le balayage du lexique et le recensement des constructions sont considérables. La délimitation systématique entre constructions figées et constructions libres est difficile à trouver ailleurs, si ce n'est dans les tables du Lexique-Grammaire d'autres langues.

En ce qui concerne les verbes distributionnels, nous avons mis à jour les entrées. Certains choix avaient été fait à une époque où les données linguistiques étaient répertoriées sur des fiches cartonnées, mais ils n'avaient jamais été répertoriés dans les versions électroniques ultérieures. De plus, un index électronique recense toutes les entrées et indique les tables dans lesquelles elles apparaissent, en donnant plusieurs exemples de phrases. Nous avons donc mis en correspondance les tables et cet index, tout en tenant compte des fiches cartonnées <sup>29</sup>.

Cependant, le découpage des verbes très fréquents, et pour lesquels il est difficile d'identifier clairement tous les sens, avait parfois été mis de côté. Une de nos priorités a été de les ajouter. Ces verbes ont donc été entièrement passés en revue pour que les tables soient les plus complètes possible. En revanche, ces verbes n'ont pas encore été codés, ce qui pose un réel problème pour leur reconnaissance dans les textes.

Afin d'illustrer ce problème, une liste de 30 verbes (en prenant en compte les formes pronominales, les pronoms clitiques figés, les adverbes obligatoires et autres) a été établie, tous étant considérés comme des verbes fréquemment représentés dans les textes. La Tab. 5.3 montre le nombre d'entrées codées et non codées pour ces verbes. On remarque qu'en moyenne les entrées non codées constituent la moitié de ces verbes.

C'est ainsi que l'on s'aperçoit que le verbe rivaliser a une entrée qui est codée dans la table 35RR de BGL, dont l'exemple est Max rivalise de générosité avec Luc. Or, il figure également sans être codé, dans la table 35S de BGL qui reconnaît Les sculptures rivalisent avec les Mayol, avec un seul argument, ce qui est le sens le plus courant.

De même, le verbe *contester* a une entrée codée dans la table 6 de M. Gross et illustrée par *Max conteste qu'il soit responsable*, et une autre entrée dans la table 9 de M. Gross

<sup>29.</sup> Nous avons réalisé ce travail en collaboration avec Christian Leclère en 2008-2009 (Tolone, 2009). Une comparaison des entrées verbales entre la première version de 2008 et la version 3.3 est réalisée à la section 9.2.

| Verbes       | Entrées | Entrées    |
|--------------|---------|------------|
|              | codées  | non codées |
| apporter     | 4       | 1          |
| avoir        | 14      | 5          |
| bouger       | 1       | 9          |
| contester    | 2       | 2          |
| craindre     | 3       | 5          |
| doser        | 2       | 2          |
| $\hat{e}tre$ | 19      | 8          |
| faire        | 15      | 14         |
| gagner       | 8       | 5          |
| jouer        | 26      | 15         |
| laisser      | 5       | 13         |
| lire         | 4       | 5          |
| manger       | 4       | 5          |
| monter       | 14      | 17         |
| passer       | 14      | 27         |
| perdre       | 13      | 9          |
| porter       | 12      | 8          |
| prendre      | 15      | 18         |
| $pr\'eparer$ | 4       | 3          |
| rattraper    | 6       | 5          |
| revenir      | 15      | 6          |
| rivaliser    | 1       | 1          |
| sembler      | 0       | 1          |
| sentir       | 4       | 6          |
| servir       | 8       | 6          |
| suivre       | 9       | 12         |
| susciter     | 0       | 2          |
| tirer        | 11      | 21         |
| trouver      | 6       | 9          |
| venir        | 11      | 6          |
| vouloir      | 5       | 2          |
| total        | 255     | 260        |

TABLE 5.3: Nombres d'occurrences d'entrées codées et non codées pour une liste de verbes fréquents

avec comme exemple Max conteste à Luc qu'il puisse occuper ce lieu. En revanche, deux autres entrées ne sont pas codées, l'une dans la table 32H de BGL qui reconnaît Max conteste le directeur, et l'autre dans la table 36DT avec pour exemple Max conteste à Jean (le+la possession du) ballon. Ce qui pose problème, puisque les deux uniques tables dont les entrées sont codées mettent en jeu des complétives.

Enfin, le verbe susciter ne possède aucune entrée codée, alors qu'il figure dans la table 36DT de BGL avec comme exemple Que Léa boive suscite des craintes à Max, ainsi que dans la table 38R de BGL qui reconnaît Ceci a suscité une (vive réplique+réaction), il ne peut donc être reconnu dans les textes. De plus, il pourrait également figurer en tant que verbe support de l'entrée espoir dans la table APE3 de noms prédicatifs, qui a comme exemple Luc a de l'espoir (E+en Max+en l'avenir). Pour cela, il suffirait d'y ajouter une construction permettant de reconnaître l'exemple (Max+L'avenir) suscite l'espoir de Luc, comme c'est le cas du verbe donner. En effet, la construction N1nr donner Det N à N0 est codée dans la table et reconnaît (Max+L'avenir) donne de l'espoir à Luc.

Notons que, même dans un lexique le plus complet possible, il est impossible de couvrir toutes les entrées car on ne peut pas établir de liste définitive, puisque de nouveaux mots apparaissent régulièrement. Dans les tables du Lexique-Grammaire, les verbes techniques ont été écartés, pour les raisons suivantes : ils sont très nombreux, ils sont plus rares dans les textes, ce qui les rend moins prioritaires. De plus, leur emploi est peu connu et donc difficiles à coder sans être spécialiste du domaine concerné. Malgré cela, une liste a été établie mais uniquement dans des fiches cartonnées.

# 5.5.3 Difficulté du codage

Nous discutons de la difficulté que représente le codage des tables du Lexique-Grammaire puisqu'il peut y avoir des erreurs ou des différences d'acceptabilité entre linguistes. Ceci peut aller jusqu'à remettre en cause sa validité, alors qu'il se prononce sur des points relativement vérifiables. Nous évoquons la possibilité d'envisager l'utilisation d'un corpus pour attester certaines phrases mais sans exhaustivité. Enfin, nous abordons la signification du signe —.

#### Validité du codage

Certaines informations contenues dans les tables du Lexique-Grammaire peuvent être incorrectes, ainsi que cela a été signalé dans Gardent et al. (2006). En effet, plusieurs sources d'erreurs expliquent la présence d'informations invalides.

Tout d'abord, il existe des erreurs matérielles. Des anomalies dans les programmes de gestion des tables ont inversé tous les signes + et - dans certaines entrées, par exemple  $traîner\ la$  dans la table 1 (entrée qui par la suite a été supprimée de table 1 des verbes et ajoutée dans la table CADV des expressions figées). Nous avons nous-même introduit, au cours de la révision des intitulés (cf. 5.3.2), plusieurs erreurs qui ont été corrigées par la suite.

Ensuite, certains verbes supports ont été codés dans les tables de verbes distributionnels. Ainsi, le verbe faire dans Max fait (du sport+du tennis+de la nage) est codé dans la table 32R3. Or, la table FD2 de L. Pivaut de noms prédicatifs décrit les noms *sport* et *tennis*, ainsi que d'autres noms dans le même cas. De même, la table FD4 de L. Pivaut décrit le nom *nage*. Il faudrait donc supprimer tous les verbes supports contenus dans les tables de verbes distributionnels, après s'être assuré que tous les noms prédicatifs correspondants sont bien codés dans les tables de noms prédicatifs.

On pourrait faire de même pour le verbe subir dans Le p'etrole subit une hausse cod'e dans la table 32NM. Or, il manque certains noms pr\'edicatifs, par exemple, le nom hausse ne figure pas dans les tables de noms pr\'edicatifs.

Il faut cependant veiller à ne pas le faire abusivement. Ainsi, le verbe avoir dans Max a une cible est codé dans la table 32R3 et le nom cible figure dans la table AN10 de A. Meunier, mais avec un sens différent : dans la table 32R3, il s'agit du sens Max a eu la cible (= il ne l'a pas ratée), alors que dans la table AN10, c'est le sens Max cible quelque chose.

Comme cela a déjà été mentionné dans Laporte (2010), la présence d'erreurs dans les tables du Lexique-Grammaire ne doit pas nous faire oublier ses points forts en ce qui concerne la validité. Les tables se prononcent explicitement sur des points vérifiables et restent assez neutres par rapport aux différentes théories syntaxiques. Ses auteurs se sont concentrés sur des phénomènes relativement vérifiables, c'est-à-dire ceux pour lesquels l'observation est aisément reproductible. Ils ont ainsi marqué l'aspect processif ou statique de certaines constructions, comme N2 V N1, illustrée par Le rideau cache le sac (statique), que nous pouvons contraster avec la construction de base de la même entrée : Luc cache le sac derrière le rideau (processif). Dans le cas de la construction N1 V Loc N2, le marquage de ce trait sémantique n'a pas été jugé suffisamment reproductible pour être systématisé: si l'aspect est nettement processif dans Le volet claque contre le mur, et nettement statique dans Le carton tient contre la caisse, l'intuition sémantique est moins claire dans Le frein frotte sur la jante. D'une manière générale, les auteurs des tables du Lexique-Grammaire se sont entourés de précautions méthodologiques en vue d'assurer la reproductibilité de leurs observations (Laporte, 2008), et le recours à l'intuition y est plus sévèrement encadré que, par exemple, dans Levin (1993). Il s'en suit une base empirique plus solide.

Il arrive qu'un cadre théorique ait une difficulté à prendre en compte un fait observé dans les tables du Lexique-Grammaire : c'est probablement ce que Hathout et Namer (1997) (p. 5) entendent par «certaines transformations sont linguistiquement incorrectes, dans le cadre théorique considéré» (HPSG), ce qui est illustré par la construction N1 se V auprès de N3hum de ce Qu P (Luc se réjouit auprès de Marie de ce que le film sorte). Cette construction à trois arguments, qui dénote un acte de parole, coexiste avec une construction à deux arguments (Que le film sorte réjouit Luc, construction de base de la table 4). Dans cette construction, on ne peut pas toujours considérer que le troisième argument, formellement absent, est en fait sémantiquement présent. Une telle situation est une anomalie par rapport à la plupart des théories actuelles.

L'incorrection en fait se situe plutôt du côté du cadre théorique que du phénomène observé. La neutralité par rapport aux théories syntaxiques explique par ailleurs le choix d'un degré de formalisation limité (cf. 5.3.2). Un formalisme plus complexe est

nécessairement plus dépendant d'une théorie, ce qui peut gêner l'observation éventuelle de faits auxquels cette théorie n'a pas été adaptée.

#### Utilisation d'un corpus

Remarquons que les différents auteurs des tables du Lexique-Grammaire peuvent avoir des différences d'interprétation et surtout une rigueur variable. Seulement deux codages sont possibles (+/-) (Harris, 1952). On peut être laxiste pour les + (c'est-à-dire permettre des phrases presque inacceptables, ce qui permet d'être plus couvrant mais augmente l'ambiguïté) ou au contraire trop intransigeant pour les - (ce qui engendre des difficultés puisque ces formes ne pourront jamais être reconnues). Ceci constitue le problème du codage binaire. On peut tout de même noter que, pour un analyseur syntaxique, il est préférable de couvrir plus pour reconnaître même les phrases rares. Le codage aurait pu être de la forme ++/+/?/-/--, mais il aurait été plus difficile d'avoir des données cohérentes d'un auteur à l'autre.

Dans les faits, les auteurs des tables du Lexique-Grammaire ont cherché à infléchir légèrement leurs jugements d'acceptabilité dans le sens de la tolérance. En effet, ils n'ont pas cherché à appuyer leurs décisions sur des attestations dans des corpus car cela était irréalisable à l'époque (Boons et al., 1976b) (p. 37). Un contrôle de la validité plus objectif aurait été lourd et aurait sans doute compromis la faisabilité du projet. La grande couverture en informations a été préférée à l'objectivité.

En effet, dans la plupart des cas, il suffit qu'un exemple soit trouvé, pour que la propriété soit considérée comme acceptée, même si elle ne l'est que dans certaines phrases ou dans certains contextes. Par exemple, N0 lieu de destination de N1 est noté + pour le verbe *hisser* (table 38L), bien qu'on puisse imaginer toutes sortes de situations dans lesquelles, si Max hisse une caisse, il ne soit pas le point d'arrivée de la caisse.

Aujourd'hui, confronter les tables du Lexique-Grammaire avec un corpus serait un travail intéressant. On pourrait en effet, rendre le codage moins binaire en indiquant une probabilité d'apparition de chaque construction pour chaque entrée après avoir appliqué un analyseur syntaxique sur un corpus de taille conséquente.

En revanche, il ne serait pas possible de relier à des attestations toutes les informations contenues dans les tables du Lexique-Grammaire. Elles représentent, pour les verbes, un balayage du lexique (environ 13 800 entrées verbales, même si toutes n'ont pas encore été codées) croisé avec un balayage d'environ 500 propriétés syntaxico-sémantiques, au cours duquel les mêmes constructions sont testées aussi bien sur les entrées rares (par exemple, godailler) que sur les entrées fréquentes (par exemple, bouillir). Un corpus représente également un balayage croisé, mais partiel, sans pouvoir garantir que la totalité des combinaisons soit passée en revue. La différence importante est qu'il n'atteste pas d'inacceptabilités. Le choix de couvrir une grande masse d'informations justifie d'ailleurs en partie aussi celui d'un degré de formalisation limité (cf. 5.3.2).

#### Signification du signe -

Une notation différente pourrait être envisagée pour la table des classes. En effet, comme nous l'avons mentionné précédemment, tous les signes — n'ont pas la même valeur, mais il n'est pas toujours évident de les distinguer rigoureusement :

- certaines propriétés ont une vraie valeur car elles ne sont acceptées par aucune entrée de la table (par exemple, N1 destination pour la table 2);
- d'autres sont codées lorsqu'elles ne sont pas pertinentes car elles dénotent un élément qui est inapproprié pour la table (par exemple, N1 destination pour la table 31H, qui a comme construction de base N0 V et n'a donc pas de complément N1, comparée à la table 2 qui a comme construction de base N0 V Loc N1 V0-inf W).

La distinction a été faite uniquement dans la table des classes des expressions figées pour tester l'utilité de cette notation. Pour cela, nous avons ajouté manuellement un signe / pour coder une propriété non pertinente uniquement dans les cas faciles à repérer comme l'exemple ci-dessus.

Lorsqu'une propriété n'est pas pertinente, c'est qu'il existe d'autres propriétés qui permettent de déduire que cette propriété n'est jamais acceptée. On pourrait formaliser ces dépendances/redondances entre propriétés, avec des formules logiques du type «si aucune construction ne contient N2 alors aucune propriété distributionnelle de l'argument N2 n'est acceptée», ce qui permettrait d'automatiser la distinction entre — et /. Mais toutes les dépendances/redondances entre entrées sont difficiles à décrire. Par exemple, les verbes pronominaux n'ont pas de passif :

Les clients s'arrachent ce modèle

\*Ce modèle s'est arraché par les clients

Mais il est difficile de savoir si c'est une propriété pertinente ou pas car il n'y a pas de critère précis, alors que ce qui sépare + de - est défini sur la base d'un jugement d'acceptabilité.

De plus, l'ajout d'un signe / ne serait qu'une information linguistique supplémentaire qui n'aurait pas de réel impact dans un analyseur. En revanche, c'est une notation qui peut aider à la détection d'erreurs dans les tables. Par exemple, si une propriété codée – pour une entrée est recodée temporairement +, le temps d'analyser un corpus de phrases contenant l'entrée correspondante afin de voir si cela change les résultats de l'analyseur, et si oui, étudier ces résultats. Les propriétés codées avec un signe / ne sont pas concernées et n'ont pas besoin d'être étudiées avec attention par des linguistes qui souhaitent revenir sur certains codages de la table des classes.

# 5.6 Bilan

Cette section résume rapidement comment les tables du Lexique-Grammaire sont effectivement utilisées dans un processus d'analyse syntaxique symbolique complet (5.6.1), avant de terminer par une analyse des avantages de cette méthode par rapport à l'approche probabiliste (5.6.2).

### 5.6.1 Explicitation du processus complet d'utilisation des tables

La version actuelle des tables a permis d'envisager une utilisation de ces données lexicales dans des outils de TAL (Tolone, 2009). A cette fin, un lexique syntaxique généré à partir des tables a été développé initialement pour les verbes et les noms (Constant et Tolone, 2010), puis pour toutes les catégories. Il s'agit du lexique *LGL*ex, que nous détaillons au chapitre 7.

Ensuite, nous avons pu intégrer une partie de ce lexique dans l'analyseur syntaxique à grande échelle FRMG (cf. section 4.2). Cette intégration a été l'objet du travail dans Sagot et Tolone (2009b); Tolone et Sagot (2011), décrit au chapitre 8, qui a permis la conversion des tables au format Alexina, le format du lexique Lefff (cf. section 4.1). L'analyseur syntaxique FRMG couplé à ce lexique a ensuite été évalué sur le corpus de référence de la campagne Passage, comme cela a été initialement fait sur le corpus de référence de la campagne EASy dans Sagot et Tolone (2009a); Tolone et Sagot (2011). Nous verrons cela au chapitre 10.

#### 5.6.2 Conclusion

Les choix faits lors de la construction des tables du Lexique-Grammaire sont motivés par un certain nombres de principes et d'objectifs parfois originaux : un vaste recensement du lexique et des constructions, la priorité donnée aux propriétés factuelles sur les contraintes liées à des théories spécifiques, une exigence de reproductibilité des observations. Ce sont ces caractères qui nous ont permis d'envisager l'exploitation des tables du Lexique-Grammaire dans des systèmes de TAL.

En effet, l'ensemble des travaux récents de récupération et de mise en cohérence de ces données linguistiques a permis d'obtenir pour l'ensemble des catégories représentées une nouvelle version des tables du Lexique-Grammaire, qui, combinée avec les tables des classes, constitue un ensemble complet et synthétique de données linguistiques.

Il est important de noter que, malgré les erreurs et les différences de jugements entre les auteurs des tables du Lexique-Grammaire, aucune approximation n'a été faite. Ces données sont donc aussi correctes que possibles. Bien entendu, les systèmes par acquisition automatique fonctionnent bien et peuvent plus facilement prendre en compte des nouveaux mots. Mais ils comportent aussi beaucoup d'erreurs car ils omettent des phénomènes rares ou absents des corpus d'apprentissage. Il existe des moyens de corriger ces erreurs, notamment au moyen de techniques automatiques, telles que celles décrites dans Sagot et de La Clergerie (2008), mais cela prend du temps et se révèle insuffisant à tout détecter. Remarquons que ces techniques peuvent être également employées pour améliorer les ressources manuelles, en corrigeant des erreurs dans les tables et permettre ainsi de les améliorer.

# 6

# Constructions de base pour toutes les catégories

Les constructions de base ont subi des changements au cours des années alors que ce sont les plus importantes à définir. L'objectif de ce chapitre est de suivre leur trace et de comprendre le sens de leur modification. Nous avons réalisé ce travail pour l'ensemble des catégories, à savoir les verbes distributionnels, les noms prédicatifs, les expressions figées et les adverbes (cf. Tab. 5.1).

Nous listons tout d'abord dans les sections 6.1 et 6.2, les modifications apportées aux constructions de base des classes des verbes distributionnels de M. Gross et de BGL. Puis, dans la section 6.3, nous passons en revues les différentes tables de noms prédicatifs, avec les différents verbes supports associés. Ensuite, dans la section 6.4, nous détaillons le cas des expressions figées et enfin, dans la section 6.5, celui des adverbes, en expliquant comment nous avons scindé deux ressources (adverbes simples et adverbes (semi-)figés) qui ne suivent pas les mêmes principes de représentation. Nous finissons par un bilan sur le nombre d'entrées par catégories et un recensement de l'ensemble des propriétés définitoires vraies pour toutes les entrées d'une table, incluant la construction de base, dans la section 6.6.

Il faut noter que nous avons ajouté, dans la table des classes concernée, toutes les propriétés définitoires vraies pour toutes les entrées d'une table, qui sont définies dans ce qui suit. Elles sont donc prises en compte lors de la conversion vers le lexique LGLex.

# 6.1 Les classes des verbes distributionnels : Les complétives et les infinitives

Les classes des verbes distributionnels de M. Gross (cf. Tab. 5.1(a)) sont au nombre de 19 lors de leur création (Gross, 1975) : de 1 à 3, les classes des infinitives et de 4 à 19, celles des complétives. Nous allons détailler pour chaque table quelle est sa construction de base actuelle et expliquer quelles sont les modifications qui ont été nécessaires, comme cela a été fait dans Tolone (2010).

Une seule table n'a subi aucun changement, il s'agit de la table 16 décrite dans Gross (1975) (p. 208), qui a pour construction de base N0 V Prép N1 Prép N2, où les arguments N1 et N2 peuvent être des complétives (Flo déduit que Guy est arrivé de ce qu'il y a du désordre). En effet, la valeur des deux prépositions et les propriétés distributionnelles des arguments N0, N1 et N2 sont codées dans la table 1. Parmi ces propriétés, on a au moins soit une complétive à l'indicatif (Qu Pind), soit au subjonctif (Qu Psubj), soit, pour l'argument N2, une infinitive coréférente avec l'argument 1 (V1-inf W). Ceci est codé par les colonnes N1 =: Qu Pind, N1 =: Qu Psubj, N2 =: Qu Pind, N2 =: Qu Psubj et N2 =: V1-inf W.

Nous expliquons les modifications de certaines constructions de base (6.1.1), l'éclatement de certaines classes (6.1.2), de simples changements de notation (6.1.3), ou encore la suppression de certaines classes (6.1.4).

#### 6.1.1 Modifications de la construction de base

La construction de base de la table 1 décrite dans Gross (1975) (p. 160) est N0 U Prép V0-inf W ( $Paul\ cesse\ de\ travailler$ ). Tout d'abord, nous pouvons remarquer que la préposition peut être vide. En effet, la colonne Prép1 contenait des -, aujourd'hui remplacés par des <E>. Une proposition avait été d'avoir comme construction de base N0 U (E+Prép) V0-inf W, mais cela introduit un OU puisque certaines entrées ont les deux formes ( $Luc\ dévale\ la\ pente\ retrouver\ ses\ amis$ ) mais ceci n'est pas une généralité.

Le signe + est une notation que l'on cherche à éviter pour ne pas rendre les intitulés ambigus car il peut avoir trois interprétations différentes :

- toutes les formes sont observées (ET);
- au moins une des formes est observée (OU);
- une et une seule des formes est observée (OU exclusif).

Comme cela a été expliqué dans Gross (1975), cette table étudie la possibilité d'insérer un verbe U dans une phrase quelconque N0 V W, c'est-à-dire apparaissant dans une phrase de forme N0 U Prép V0-inf W, tout en observant les relations entre N0 et V W,

<sup>1.</sup> Rappelons que les arguments pouvant être des complétives ne font pas obligatoirement l'objet d'une propriété définitoire, mais parfois de plusieurs colonnes codées dans la table elle-même, ceci pour permettre de distinguer les complétives à l'indicatif, au subjonctif, les complétives interrogatives (si P ou si P) et les infinitives (V-inf W) et pour permettre également de reconnaître d'autres catégories grammaticales (comme les syntagmes nominaux, avec les propriétés Nhum et N-hum).

pour savoir si le verbe U impose ou non des contraintes sur N0, ce qui est codé par la colonne N0 =: Nnc (non contraint).

Considérons par exemple la phrase :

(Pierre+Cette affaire+Cette table+Faire ceci) amuse Paul

Si l'on y insère le verbe continuer à -inf, nous obtenons la séquence tout à fait acceptable, où la relation entre N0 et V W reste inchangée :

(Pierre+Cette affaire+Cette table+Faire ceci) continue à amuser Paul

En revanche, le verbe se dépêcher de -inf n'est insérable que dans les phrases à sujet humain :

\*(Cette affaire+Cette table+Faire ceci) se dépêche d'amuser Paul Pierre se dépêche d'amuser Paul

Or, seul un petit nombre de verbes correspondent à cette étude, à savoir uniquement ceux de la table 1. Le lien entre les deux phrases N0 V W et N0 U Prép V0-inf W n'étant pas exploitable informatiquement et pour rester conforme à la notation des entrées verbales des autres tables, nous avons remplacé U par V. La construction de base de la table 1 est donc N0 V Prép V0-inf W (cf. Fig. 3.3).

La construction de base de la table 3 décrite dans Gross (1975) (p. 168) est N0 V N1 V1-inf W (On a emmené Luc se faire soigner). Il s'avère que l'on peut toujours insérer un complément locatif (Loc N2) avant le verbe à l'infinitif, la préposition locative étant codée dans la table (à, dans ou de). Nous avons donc retenu la construction de base la plus complète, qui est N0 V N1 Loc N2 V1-inf W, ce qui n'empêche pas de garder également N0 V N1 V1-inf W comme construction définitoire. De plus, l'infinitive peut être supprimée pour toutes les entrées, donc N0 V N1 Loc N2 est acceptée comme troisième construction définitoire. Reprenons l'exemple précédent pour illustrer ces trois constructions :

On a emmené Luc à l'hôpital se faire soigner On a emmené Luc à l'hôpital On a emmené Luc se faire soigner

# 6.1.2 Éclatement en plusieurs classes

Nous avons procédé à l'éclatement en plusieurs classes quand cela s'est révélé nécessaire. C'est le cas de la table 2 dont la construction de base décrite dans Gross (1975) (p. 165) est N0 V (E+N1) V0-inf avec un *OU exclusif* (*Max fonce retrouver ses co-pains / La foule envahit la place manifester sa joie*). Cela signifie que certaines entrées acceptent un complément N1 direct et d'autres non, sans que cela ne soit codé. Or, une propriété dite définitoire pour une classe est considérée comme étant acceptée pour toutes les entrées, sans exception. Nous avons donc créé une nouvelle table 2T regroupant toutes les entrées transitives (acceptant un N1), en les supprimant de la table 2. Cela a été fait manuellement pour chaque entrée car aucune indication n'était donnée dans la littérature <sup>2</sup>. De plus, après avoir fait ce découpage, il s'avère que toutes les entrées

<sup>2.</sup> Nous avons réalisé ce travail en collaboration avec Christian Leclère en 2008 (Tolone, 2009).

non transitives acceptent un complément locatif (Loc N1) qui peut même être parfois obligatoire :

Max s'enfourne dans le tunnel chercher Luc

\*Max s'enfourne chercher Luc

La table 2 a donc comme construction de base N0 V Loc N1 V0-inf W mais également N0 V Loc N1 comme deuxième construction définitoire, car l'infinitive peut être supprimée. On a une colonne N0 V V0-inf W qui code la facultativité du complément locatif et qui est très souvent codée + :

Max fonce dans le jardin retrouver ses copains

Max fonce dans le jardin

Max fonce retrouver ses copains

La table 2T a comme construction de base  $N0 \ V \ N1 \ V0$ -inf W et comme deuxième construction définitoire  $N0 \ V \ N1$  car l'infinitive peut être supprimée. On a cette même colonne  $N0 \ V \ V0$ -inf W, codée dans la table 2, qui code ici la possibilité d'omission du N1 et qui est très souvent codée -:

La foule envahit la place manifester sa joie

La foule envahit la place

\*La foule envahit manifester sa joie

# 6.1.3 Changement de notation

La construction de base de la table 4 décrite dans Gross (1975) (p. 170) est Qu P V N1, avec la colonne N0 =: Nnr codée + pour toutes les entrées (Que Paul vienne amuse Luc). Comme cela a été expliqué dans Gross (1975), la notation Nnr désigne un substantif non restreint, c'est-à-dire un substantif d'une nature sémantique quelconque, une complétive ou une infinitive. Le test employé consiste à placer, dans la position à étudier, les groupes nominaux Paul (humain), ce gâteau (concret, énumérable, ou non), la sincérité (abstrait), Qu P et V-inf W. Les phrases résultantes doivent toutes être acceptables. Nous avons par exemple :

(Paul+Ce gâteau+L'amour+Que Paul vienne+Faire cela) ennuie Marie

Nous avons donc supprimé la colonne N0 =: Nnr de la table et l'avons définie comme propriété définitoire. Puis, nous avons transformé la construction de base en N0 V N1, avec N0 =: Qu P, afin de garder la propriété définissant la table, malgré le fait que la complétive Qu P est déjà incluse dans Nnr. Nous avons également ajouté la propriété définitoire N1 =: Nhum.

La construction de base de la table 5 décrite dans Gross (1975) (p. 172) est Qu P V Prép N1 (Que Marie vienne importe à Paul). Nous l'avons simplement remplacée par N0 V Prép N1, avec la propriété définitoire N0 =: Qu P. Ce choix de notation permet de réutiliser les mêmes intitulés dans un maximum de tables et facilite la récupération des différentes réalisations de chaque argument. De plus, la table 5 a la propriété définitoire [extrap], qui correspond à la construction II V N0 Prép N1.

Ce même procédé a été appliqué à la table 12 décrite dans Gross (1975) (p. 201), qui a comme construction de base N0 V Qu Psubj, avec P = N1 V1-inf W (P fai-

sant référence à la forme de la complétive de la construction de base) et comme transformation N0 V N1 de V1-inf W (Paul apprécie que Léa l'ait aidé / Paul apprécie Léa de l'avoir aidé). Nous avons remplacé la construction de base par N0 V N1, avec la propriété définitoire N1 =: Qu Psubj. La transformation devient Qu Psubj =: Qu Ni Vsubj W = (Ni) (de Vi-inf W) afin de la rendre plus explicite et est définitoire également. La notation i permet de bien différencier le Ni, sujet de la complétive et le N1, premier complément.

La construction de base de la table 6 décrite dans Gross (1975) (p. 177) est N0 V Qu P (Paul estime que Luc a raison). Le fait que l'argument N1 puisse être une complétive est représenté par les trois colonnes N1 =: Qu Pind, N1 =: Qu Psubj et N1 =: si P ou si P codées dans la table. Nous avons gardé N0 V N1 comme construction de base puisque le complément N1 n'accepte pas toujours une complétive. De plus, cela permet de clarifier à quel argument font référence les colonnes précédentes.

La même méthode a été reproduite :

- les tables 7, 8, 9, 10, 14 et 15 ont N0 V à ce Qu P (respectivement, N0 V de Qu P, N0 V Qu P à N2, N0 V Qu P Prép N2, N0 V à ce Qu P Prép N2 et N0 V de ce Qu P Prép N2) comme construction de base dans Gross (1975) (p. 184, 187, 190 et 193):

Paul consent à ce que Marie fasse ça (table 7)

Paul s'insurge de ce que Marie ait fait ça (table 8)

Paul crie à Léa que tout est fini (table 9)

Ceci comporte pour Flo qu'elle doit partir tôt (table 10)

Cette règle équivaut pour Paul à ce que Léa soit élue (table 14)

Paul répond devant le juge de ce que Léa a fauté (table 15)

Le fait que l'argument N1 puisse être une complétive est représenté par les deux colonnes N1 =: Qu Pind et N1 =: Qu Psubj codées dans les tables, plus la colonne N1 =: V0-inf W pour les tables 7 et 8, et plus la colonne N1 =: si P ou si P pour la table 9. Nous avons changé leur construction de base en N0 V à N1 pour la table 7, N0 V de N1 pour la table 8, N0 V N1 à N2 pour la table 9, N0 V N1 Prép N2 pour la table 10, N0 V à N1 Prép N2 pour la table 14 et N0 V de N1 Prép N2 pour la table 15. De plus, la table 9 a la propriété définitoire N2 = : Nhum.

– les tables 11 et 13 ont  $N0 \ V \ N1$  à ce  $Qu \ P$  (respectivement,  $N0 \ V \ N1$  de ce  $Qu \ P$ ) comme construction de base dans  $Gross \ (1975)$  (p. 197 et 203) :

Max a dressé Luc à ce qu'il se lève tôt (table 11)

Paul informe Luc de ce que Léa arrive (table 13)

Le fait que l'argument N2 puisse être une complétive est représenté par les trois colonnes N2 =: Qu Pind, N2 =: Qu Psubj et N2 =: V1-inf W codées dans les tables, plus N2 =: V0-inf W pour la table 11. Nous avons remplacé leur construction de base par N0 V N1 à N2 pour la table 11 et N0 V N1 de N2 pour la table 13.

la table 18 décrite dans Gross (1975) (p. 212), a comme construction de base
 N0 V Prép N1 Prép N2 (E+pour) Qu Psubj (Ça a servi à Paul de prétexte pour qu'il ne vienne pas). Le fait que l'argument N3 puisse être une complétive est représenté par les deux colonnes N3 =: Qu Pind, N3 =: Qu Psubj codées dans la table. Il est vrai

que pour la majorité des entrées, une complétive au subjonctif est acceptée (sauf une entrée qui accepte uniquement une complétive à l'indicatif) et que la préposition en position 3 vaut toujours pour ou  $\langle E \rangle$ , cependant une information non valable pour toutes les entrées n'a pas à figurer dans la construction de base, que nous avons donc corrigée par N0 V Prép N1 Prép N2 Prép N3.

# 6.1.4 Suppression de classes

Les tables 17 et 19 ont été supprimées, elles avaient il V (E+Prép ce) Qu P (E+Prép N2) (respectivement, Qu P V N1 Prép N2) comme construction de base dans Gross (1975) (p. 211 et 213) :

Il paraît que Max est franc-maçon (table 17)

Que Léa soit partie ôte tout espoir à Luc (table 19)

La table 19 contenait en effet très peu d'entrées, et elles avaient leur place dans d'autres tables de verbes distributionnels de BGL (Guillet et Leclère, 1992) comme 36DT (apporter, ôter), 36SL (désaccoupler), 37M4 (remplir) et 36R (servir), qui ont N0 V N1 Prép N2 comme construction de base (ou N0 V N1 à N2 pour 36R), ce qui correspond bien à la construction initiale. Notons tout de même que nous avons accepté une perte d'information pour ces entrées, puisque la propriété N0 =: Qu P n'est pas codée dans ces tables 3.

En ce qui concerne les entrées de la table 17, elles sont considérées comme des expressions figées car le sujet *il* est figé. Nous les avons ajoutées principalement dans la table d'expressions figées de Gross (1982) COQ (*il s'agir pour ... de, il apparaître à, il paraître*, etc) qui a comme construction de base Det0 C0 V Prép1 (Det1 C1+N1) Prép2 N2.

# 6.2 Les classes des verbes distributionnels de BGL

Les classes des verbes distributionnels de BGL (cf. Tab. 5.1(a)) étaient au nombre de 40 lors de leur création : 15 classes de constructions transitives (Boons et al., 1976a), 9 classes de constructions intransitives (Boons et al., 1976b) (dont une est considérée actuellement comme une classe d'expressions figées) et 16 classes de constructions transitives locatives (Guillet et Leclère, 1992). Nous allons présenter en détail les modifications apportées aux constructions de base, comme nous l'avons déjà fait dans Tolone et al. (2010). Nous commençons par voir les changements de notation (6.2.1), puis les classes pour lesquelles nous avons dû spécifier les propriétés distributionnelles de leurs arguments (6.2.2). Ensuite, nous détaillons le cas de deux classes qui ont été divisées chacune en quatre classes (6.2.3), puis des trois classes qui n'ont jamais été publiées (6.2.4), et enfin d'une nouvelle classe qui a été créée (6.2.5). Puis, un exemple d'ajout d'intitulé est donné (6.2.6), avant de terminer par un inventaire des classes restantes, n'ayant pas subi de modification (6.2.7).

<sup>3.</sup> La propriété N0 =: Qu P devrait être codée dans toutes les tables car elle est variable selon les entrées (codage O). En effet, les tables de M. Gross couvrent bien l'ensemble des complétives objet mais pas des complétives sujet, la table 5 regroupant uniquement celles entrant dans la construction  $N0 \ V \ Prép \ N1$ .

### 6.2.1 Changement de notation

La construction de base de la table 32R1 (Résiduel à restructuration) décrite dans Boons et al. (1976a) (p. 76) est N0 V N1 de N1c = N0 V N1c Loc N1 (Ceci confirme les soupçons de Marie / Ceci confirme Marie (\*E+dans ses soupçons)). Nous avons décidé de noter la construction de base simplement N0 V N1. De plus, nous y ajoutons comme définitoire, la restructuration N0 V (N1 de N1c) = N0 V (N1c) (Prép N1). Elle signifie que l'objet direct nominal de la forme N1 de N1c, où N1c est un complément de nom, peut être remplacé par N1c et le complément prépositionnel Prép N1. Nous avons également ajouté les propriétés définitoires N1 =: Nabs et [passif par]. Le complément prépositionnel peut être facultatif (Luc stimule la curiosité de Marie / Luc stimule Marie (E+dans sa curiosité)). Ceci est codé dans la table par la colonne N0 V N1c.

La construction de base de la table 34L0 (Locatif en position N0) décrite dans Boons et al. (1976b) (p. 242) est la construction standard Ni V Loc Nj et la construction croisée Nj V de Ni (L'intelligence étincelle dans son regard / Son regard étincelle d'intelligence). Tout d'abord, la notation i et j d'origine a été abandonnée : N0 V Loc N1 et N1 V de N0. Puis, nous avons renommé la construction croisée N1 V Prép N0 avec Prép0 =: de définitoire, car dans la table, une deuxième préposition est possible et codée par Prép0 =: en. Il y a également la propriété N1hum V Prép N0 qui est codée dans la table, mais elle ne sert qu'à spécifier que le N1 est humain.

La construction de base de la table 38L (Locatif double) décrite dans Guillet et Leclère (1992) (p. 123 et 219) est N0 V N1 de N Loc N, le complément de N Loc N n'étant pas numéroté et étant défini par deux possibilités :

- de N Loc N est indissociable, comme dans :
  - Max balade le spot de la porte à la fenêtre
  - \*Max balade le spot de la porte
  - \*Max balade le spot à la fenêtre
- le premier N est interprété comme une source dépendante, c'est-à-dire employée seulement en présence de la destination, et le deuxième comme une destination, ainsi :

Max traîne cette valise du salon dans la chambre

\*Max traîne cette valise du salon

Max traîne cette valise dans la chambre

La numérotation étant indispensable, surtout pour indiquer la possibilité d'effacement du premier complément, nous avons changé la construction de base en N0 V N1 Loc N2 source Loc N3 destination, avec les deux propriétés définitoires N2 lieu source de N1 et N3 lieu de destination de N1. De plus, contrairement à la définition, les sources n'étant pas toutes dépendantes ( $Max\ transporte\ du\ blé\ de\ Gap\ (E+\grave{a}\ Dax)$ ), les deux colonnes N0 V N1 de N2 source et N0 V N1 Loc N3 destination sont codées dans la table. On a de plus le fait que la propriété N1 =: Nhum n'est pas obligatoire  $^4$ , ce

<sup>4.</sup> Ceci est à mettre en opposition avec la table 38LH qui a la propriété N1 =: Nhum obligatoire, ce qui implique que la propriété N1 =: N-hum est codée -.

que nous avons traduit par le codage + de la propriété N1 =: N-hum, la propriété N1 =: Nhum restant à coder (codage O).

La construction de base de la table 36SL (Symétrique Locatif) décrite dans Guillet et Leclère (1992) (p. 229) est la construction locative standard N0 V N1 (avec+Loc) N2, avec la possibilité d'interchanger N1 et N2 (qui n'est pas codée) et la construction symétrique N0 V N1 et N2. Elle reconnaît :

Luc colle la fiche bleue sur la fiche jaune

Luc colle la fiche jaune sur la fiche bleue

Luc colle la fiche bleue et la fiche jaune

L'objet N2  $\operatorname{est}$ interprété comme un lieu, soit N2 lieu source de N1, N2 lieu de destination de N1, mais ces deux colonnes sont à coder (codage O). La colonne Prép2 =: avec est codée dans la table. Or, quand cette propriété n'est pas acceptée, c'est la propriété Prép2 =: d'avec qui est vraie, nous l'avons donc ajoutée pour la coder explicitement avec le codage inverse. Nous avons défini N0 V N1 Prép N2 comme construction de base, qui est à associer aux deux colonnes Prép2 =: avec et Prép2 =: d'avec; et N0 V N1 Loc N2 comme deuxième construction définitoire, qui est à associer aux différentes prépositions locatives pour le complément N2 codées dans la table (de, dans, sur, contre et à); sans oublier la construction symétrique N0 V N1 et N2 également comme construction définitoire ( $Max\ a\ cogné\ son\ verre\ (avec+contre+et)$ celui de Luc).

La construction de base de la table 38LD (Locatif Destination) décrite dans Guillet et Leclère (1992) (p. 123 et 153) est N0 V N1 Loc N2, avec N2 destination, que nous avons remplacée par la construction de base N0 V N1 Loc N2 destination (*Max applique du vernis sur le meuble*). Nous avons ajouté les propriétés définitoires avec N2 lieu de destination de N1 et N1 =: N-hum.

La construction de base de la table 38LS (Locatif Source) décrite dans Guillet et Leclère (1992) (p. 123 et 167) est N0 V N1 Loc N2, avec N2 source, que nous avons codée N0 V N1 Loc N2 source (Max a arraché le clou de la planche). Nous avons ajouté les propriétés définitoires avec N2 lieu source de N1 et N1 =: N-hum.

La construction de base de la table 38LR (Locatif Résiduel) décrite dans Guillet et Leclère (1992) (p. 123 et 175) est N0 V N1 Loc N2 (sans source ni destination : Paul a agencé les bibelots sur la cheminée). Nous avons ajouté les propriétés définitoires N2 lieu statique de N1 et N1 =: N-hum.

# 6.2.2 Spécification de propriétés distributionnelles

Pour un grand nombre de classes, la construction de base est bien représentée mais il manque des propriétés distributionnelles spécifiques pour un argument, contenant pour la plupart des informations sémantiques.

La construction de base de la table 32A (Apparition) décrite dans Boons et al. (1976a)

(p. 12) est N0 V N1 apparition, ce qui signifie que l'objet N1 est interprété comme apparaissant ou étant créé au cours du procès. C'est le cas dans *Max a bâti une maison*, où la maison n'existe pas avant que l'action ne se soit déroulée. Dans un souci de réutilisabilité des intitulés et de simplification des informations sémantiques des arguments, nous l'avons séparée en deux : la construction de base N0 V N1 et la propriété définitoire N1 apparition. Nous avons ajouté la propriété définitoire [passif par]. De plus, il est spécifié que la moitié des entrées acceptent un complément Prép N2 qui peut être de deux types :

- (dans+de+en) N2, codé par les propriétés N0 V N1 de N2 matériau et N0 V N1 Loc N2 matériau, Loc # de<sup>5</sup>, marquant le matériau qui a servi à constituer le N1 (Jean a construit une maison (de+en) briques creuses);
- Loc N2, codé par la propriété N0 V N1 Loc N2, qui marque explicitement un rapport de lieu (interprété comme une destination) entre N1 et N2 (Jean a construit sa maison sur un terrain argileux).

Ces compléments sont quelquefois compatibles à l'intérieur d'une même phrase (*Jean a construit une maison en brique dans son champ*), ce qui pose problème puisque les deux sont numérotés N2. La table devrait sans doute être dédoublée comme cela a été fait pour les tables 35L et 38LH (cf. 6.2.3).

La construction de base de la table 32CV (ConVersion) décrite dans Boons et al. (1976a) (p. 14) est N0 V N1 (E+en V-n), V-n désignant le nom issu du verbe V (Max a roulé les papiers (E+en un mince rouleau)). Afin d'éviter le +, ayant pour valeur ET ici, qui peut prêter à confusion, nous avons choisi de mettre deux constructions définitoires (mais pas de base), qui sont N0 V N1 et N0 V N1 en V-n. De plus, il est spécifié que tous les verbes contiennent un substantif qui dénote le résultat du procès et qui est interprété comme une apparition après un processus de conversion (caraméliser du sucre = le (convertir+transformer) en caramel, torsader des fils = les mettre en torsade). C'est pourquoi nous avons également défini la propriété définitoire N2 apparition et N2 être V-n, le reste étant codé par les deux colonnes V = convertir en V-n et V = mettre en V-n. Enfin, nous avons mis N0 V N1 en N2 comme construction de base (et non pas N0 V N1 en V-n) car le V-n est difficile à prendre en compte dans les systèmes de TAL et peut se généraliser ici par un syntagme nominal quelconque (Max a roulé les papiers en boule). Cela permet également de clarifier la position du N2 pour la propriété définitoire N2 apparition.

La construction de base de la table 38PL (N2 Pluriel) décrite dans Boons et al. (1976a) (p. 5 et 19) est N0 V N1hum en N2 plur obl, ou plutôt N0 V N1-hum en N2 plur obl après rectification (Max analyse la phrase en deux constituants). Pour les mêmes raisons que précédemment, les différentes informations sémantiques des arguments étant codées à part, nous avons remplacé la construction de base par N0 V N1 en N2 avec N2 =: Npl obl. De plus, nous avons supprimé la colonne N1 =: N-hum de la table afin de la rendre définitoire également.

<sup>5.</sup> Loc # de désigne une préposition locative différente de de.

La construction de base de la table 32PL (Pluriel) décrite dans Boons et al. (1976a) (p. 5 et 24) est N0 V N1 plur obl (E+en N2) (Max compile des données (E+en tables)). La colonne N0 V N1 en N2 étant codée dans la table, nous avons gardé comme construction de base N0 V N1, avec la propriété définitoire N1 =: Npl obl. Nous avons ajouté la propriété définitoire [passif par]. D'autres colonnes sont codées dans la table : N0 V N1 de N2 source, N0 V N1 Loc N2 source, Loc # de, N0 V N1 Loc N2 source Loc N3 destination, ainsi que différentes prépositions locatives pour le complément N3 telles que dans, sur, contre et à. La propriété N0 V N1 Loc N3 destination devrait peut-être également être ajoutée.

La construction de base de la table 32CL (Corps Locatif) décrite dans Boons et al. (1976a) (p. 66) est N0 V N1pc de N1c, N1c étant un complément du nom N1pc (Jean a attrapé le bras de Paul). Nous avons simplifié la notation du complément N1pc de N1c par N1 en admettant comme construction de base N0 V N1, avec N1 =: Npc. Nous avons également ajouté les propriétés définitoires N0 V N1 Loc N1pc W et [passif par].

La construction de base de la table 32C (Concret) décrite dans Boons et al. (1976a) (p. 69) est la même que pour la table 32CL, sa construction de base est N0 V N1 (*L'immobilité a ankylosé le genou de Paul*), mais la propriété N1 =: Npc est variable. Nous avons également ajouté les propriétés définitoires N1 =: N-hum et [passif par]. Enfin, la table 32C a la propriété distributionnelle N1 =: Nconc définitoire (p. 73).

Il est important de remarquer que tous les Npc sont des Nconc, mais l'inverse n'est évidemment pas vrai. Or la définition de la table 32C a évolué, elle accepte des Nconc qui ne sont pas des Npc (*Luc a abîmé le livre*). C'est pourquoi la colonne N1 =: Npc n'est pas définitoire mais variable, il faudrait donc la coder (codage O). La construction de base de la table 32CL est donc N0 V N1, avec N1 =: Npc, alors que celle de la table 32C est N0 V N1, avec N1 =: Nconc.

Les propriétés suivantes sont décrites également comme étant définitoires mais sont en fait codées dans les tables : pour la table 32CL, N0 lui V N1pc W et N0 V N1c Loc N1pc W ou plutôt N0 V N1 Loc N1pc W car la distinction entre N1 et N1c n'est pas faite ici ; et pour la table 32C, N0 lui V N1pc W et N1 être Vpp W.

La table 35S (Symétrique), décrite dans Boons et al. (1976b) (p. 207), regroupe les verbes acceptant la construction standard N0 V Prép N1, avec Prép =: avec+d'avec et la construction symétrique N0 et N1 V (Max boxe avec Luc / Max et Luc boxent (E+ensemble+l'un avec l'autre)). Or, les colonnes Prép =: avec, Prép =: d'avec et d'autres (dans, à et de) sont codées dans la table, mais Prép =: avec étant codée + pour toutes les entrées, nous avons pu la supprimer de la table. En revanche, Prép =: d'avec doit figurer dans la table puisqu'elle n'est acceptée que pour certaines entrées. Nous avons donc gardé N0 V Prép N1 comme construction de base, avec Prép =: avec définitoire, et N0 et N1 V comme deuxième construction définitoire.

La construction de base de la table 36DT (DaTif) décrite dans Guillet et Leclère (1992) (p. 123 et 237) est  $N0 \ V \ N1 \ a$  N2, avec N0 = : Nhum et N2 = : Nhum (il y a une notion d'échange entre N0 et N2, qui sont tous les deux humains). Le complément N2 est

soit interprété comme bénéficiaire du référent du N1 (Paul accorde un prêt), soit comme perdant le référent du N1 (Luc a acheté cet immeuble à Marie, où Marie ne possède plus l'immeuble après le procès). Le premier cas est codé par la colonne N2 bénéficiaire. Nous avons explicité le deuxième cas en ajoutant la colonne N2 détrimentaire, contenant le codage inverse. Le complément N2 peut se pronominaliser en Ppv =: lui (lui est pris ici comme représentant canonique de la classe des Ppv au datif : me, te, lui, se, nous, vous, leur). La table reconnaît par exemple Max passe un stylo à Ida et Max lui passe un stylo. La préposition pouvant être à ou de (Max a perçu son salaire de Luc), deux colonnes sont codées dans la table : Prép2 =: à et N0 V N1 de N2 source (notation qui permet d'indiquer également que le complément N2 est interprété comme une source). Les propriétés distributionnelles N0 = : Nhum et N2 = : Nhum sont définitoires. En revanche, la propriété distributionnelle N2 =: N-hum étant codée dans la table, nous avons dupliqué le codage de la colonne pour la propriété distributionnelle N0 = : N-hum qui n'était pas codée. De plus, Ppv =: lui désigne ici la propriété définitoire mais également la propriété codée dans la table dépendante de N2 =: N-hum. Nous avons renommé la propriété définitoire Prép N2hum = Ppv =: lui. Quant à la colonne nommée Ppv =: lui, nous l'avons renommée Prép N2-hum = Ppv =: lui (Ceci retire du charme à la maison et Ceci lui retire du charme). De plus, comme le N2 (qu'il soit humain ou non) peut toujours se pronominaliser en lui, elle contient également le même codage que N2 =: N-hum, soit un - lorsqu'il n'y a pas de <math>N2-hum.

La construction de base de la table 32RA (Rendre Adj) décrite dans Boons et al. (1976a) (p. 6 et 34) est N0nr V N1 (E+de N2) (La rouille affaiblit cette poutre). La construction de base est donc NO V N1, avec NO =: Nnr définitoire ((Jean+La chaleur+Le produit solaire+Rester sur la plage) a séché l'épiderme de Marie). Nous avons ajouté la propriété définitoire [passif par]. Cette table regroupe des verbes en relation morphologique avec un adjectif et accepte également la construction NO rendre N1 (E+plus) V-adj (La rouille rend (E+plus) faible cette poutre). Le + dans cette construction a une valeur de OU exclusif, puisque certaines entrées acceptent uniquement la propriété N0 rendre N1 V-adj (sans adverbe comparatif), comme Ce produit active la fermentation = Ce produit a rendu la fermentation active, et d'autres uniquement la propriété N0 rendre N1 plus V-adj (avec adverbe comparatif), comme Le vent a abaissé la température = Le vent a rendu la température plus basse. La construction N0 rendre N1 (E+plus) V-adj a été dédoublée et codée dans la table <sup>6</sup>. De plus, certains verbes acceptent un complément prépositionnel de N2, mais pas tous. Le + dans Norr V N1 (E+de N2) a donc une valeur de OU exclusif, c'est pourquoi le complément de N2 ne figure pas dans la construction de base. Ce complément peut être de trois types comme décrit p. 51:

N0 V N1 de combien : Jean a allongé son chemin de 30 mètres
 Ce complément supplémentaire, introduit par la préposition de, précise une quantité

<sup>6.</sup> Grâce au codage de certaines informations concernant les V-n, et en l'occurrence les V-adj, dans les tables de verbes (Paumier, 2003). Ce codage n'ayant pas été maintenu dans la version actuelle des tables, il a été réintégré par Sébastien Paumier début 2011.

ou une mesure intéressant le procès, est souvent à déterminant numéral et répond à la question en de combien ?;

- N0 V N1 de N2 (enlever) : Luc a purgé ce radiateur d'un peu d'air qui peut être paraphrasée par N0 enlever N2 de N1 (Luc a enlevé un peu d'air de ce radiateur);
- N0 V N1 de N2 (mettre) : Paul a alourdi son sac d'un gros livre qui peut être paraphrasée par N0 mettre N2 Loc N1 (Pierre a mis un gros livre dans son sac).

Dans la table, trois colonnes sont codées :

de combien?

N0 V N1 de N2 = N0 enlever N2 Loc N1 (à l'origine V = enlever)

N0 V N1 de N2 = N0 mettre N2 Loc N1 (à l'origine V = mettre)

Ces deux dernières codant uniquement les paraphrases, nous avons ajouté la colonne N0 V N1 de N2, valant + dès qu'une des deux colonnes précédentes vaut +. Cette information est redondante mais permet d'expliciter la construction non déductible autrement. De plus, cela rend la notation = conforme à son utilisation, qui est de spécifier une propriété transformationnelle (à droite) à partir d'une construction déjà existante (à gauche).

La construction de base des tables 37E (Enlever) et 37M1 à 37M6 (Mettre) décrite dans Guillet et Leclère (1992) (p. 123 et 130) est N0 V N1 de N2, avec les propriétés N1 source pour la table 37E, et N1 destination pour les tables 37M1 à 37M6. Nous n'avons pas gardé la propriété N1 source pour la table 37E car en réalité cette table accepte soit la propriété N1 lieu source de N2 (Max cure le puits de sa vase), soit la propriété N1 détrimentaire (Max a possédé Luc de 100 euros), colonnes qui sont à coder (codage O). De même, pour la table 37M1 (non locatif), la destination est sémantique et non locative, elle a le sens de bénéficiaire (Max goinfre Bob de gâteaux). Nous avons considéré qu'un argument bénéficiaire ne peut pas être en même temps un lieu, ce n'est donc pas la propriété N1 destination qui est définitoire mais la propriété N1 bénéficiaire. Cette propriété distingue la table 37M1 des tables 37M2 à 37M6, de même qu'elle distingue la table 36DT des tables 38LD à 38LHR (voir l'annexe G). Pour les tables 37M2 à 37M6, la propriété définitoire a été renommée N1 lieu de destination de N2 (Luc sale le rôti de sel fin).

La seule préposition possible pour la table 37E étant de, la construction de base est N0 V N1 de N2. En revanche, la construction de base des tables 37M1 à 37M6 est N0 V N1 Prép N2 avec Prép2 =: de, pour permettre de coder dans les tables les prépositions supplémentaires avec, dans et en.

Le sens des verbes en 37E est enlever (Max débarrasse le lit des oreillers = Max enlève les oreillers du lit), la paraphrase N0 V N1 de N2 = N0 enlever N2 de N1 est donc définitoire. Celui des verbes en 37M1 à 37M6 est mettre (Max couvre le lit d'oreillers = Max met des oreillers sur le lit), codé par la paraphrase N0 V N1 de N2 = N0 mettre N2 Loc N1 définitoire.

Dans les tables 37M1 à 37M6, la productivité du préfixe  $d\acute{e}$ - permet de fabriquer un grand nombre de verbes de type 37E. Ces verbes n'apparaissent pas en tant qu'entrées du lexique, mais sont à reconstruire lorsque la colonnes  $d\acute{e}$ -V est dans l'une des tables 37M1 à 37M6. Cette colonne n'est pas exploitée car le préfixe dépend des verbes ( $d\acute{e}$ -pour coloniser, à contraster avec  $d\acute{e}s$ - pour occuper).

La différence entre les tables 37M2 à 37M6 est principalement sémantique ou morphologique. De plus, les critères justifiant leur découpage ne sont pas définissables clairement et n'ont pas la moindre reproductibilité, c'est pourquoi ces tables ont été regroupées dans l'annexe F (voir section 7.3 avec N2 =: déformation). Cela a tout de même été codé pour justifier l'existence de chacune des tables et ne rien laisser implicite :

- dans la table 37M2 (trace), le corrélat N2 du lieu N1 est un substantif indiquant des traces ou des marques (Paul a paginé ses feuilles de numéros fantaisistes). La propriété N2 =: trace a été ajoutée et est définitoire pour cette table;
- dans la table 37M3 (déformation), on a une modification du lieu N1 : le N2 ne dénote pas un objet concret adjoint à N1, mais le type de déformation subit par ce dernier (Paul a cabossé le plateau de grosses bosses). La propriété N2 =: déformation a été ajoutée et est définitoire pour cette table;
- dans la table 37M4 (résiduel), le N1 est clairement un lieu, et le N2, corrélat de ce lieu, représente un objet concret non relié morphologiquement au verbe (Paul parsème la table de miettes);
- dans les tables 37M5 et 37M6 (apport), le N2, corrélat du lieu N1, est de la forme
   N de V-n (respectivement, V-n de N), le V-n étant le représentant canonique de la classe des substantifs possibles dans cette position :
  - On a empierré la route de (E+une couche de) pierres (table 37M5)
  - Paul assaisonne son plat de (E+un assaisonnement de) épices exotiques (table 37M6)
  - La propriété N2 =: N de V-n a été ajoutée et est définitoire pour la table 37M5, ainsi que N2 =: V-n de N pour la table 37M6.

De plus, les tables 37M1 à 37M6 avaient comme propriétés distributionnelles codées dans les tables N1 =: Nhum obl et N2 =: Nhum obl. Lorsque par exemple, N1 =: Nhum obl est codée +, cela signifie que N1 =: Nhum est vraie et N1 =: N-hum est fausse. Mais lorsque N1 =: Nhum obl est codée -, cela signifie que soit les deux propriétés précédentes sont vraies, soit uniquement N1 =: N-hum est vraie. La notation hum obl a donc été supprimée puisqu'elle ne permet pas de renseigner complètement la propriété N1 =: Nhum.

Nous avons donc dupliqué la colonne  $N1 =: Nhum \ obl$  (respectivement,  $N2 =: Nhum \ obl)$  en la renommant d'une part en N1 =: Nhum (respectivement, N2 =: Nhum) en substituant tous les - par des  $\sim$ , et d'autre part en N1 =: N-hum (respectivement, N2 =: N-hum) en inversant les + et les -. Bien sûr, le codage reste à compléter pour les colonnes N1 =: Nhum et N2 =: Nhum, mais cela à l'avantage de coder explicitement les deux colonnes, comme cela est fait dans toutes les autres tables.

La construction de base de la table 32R2 (Résiduel) décrite dans Boons et al. (1976a) (p. 79) est N0 V N1 sans aucune autre contrainte (Les pluies ont accentué les crues). Nous avons ajouté les propriétés définitoires N1 =: Nabs et [passif par].

# 6.2.3 Éclatement en plusieurs classes

Comme nous l'avons mentionné en 6.1.2, nous avons dédoublé la table 2 car elle acceptait un complément N1 direct pour certaines entrées et pour d'autres non. La nou-

velle table 2T regroupe donc toutes les entrées transitives. Pour des raisons totalement différentes, nous avons également divisé la table 35L, ainsi que la table 38LH, comme nous le montrons à présent <sup>7</sup>.

La construction de base des tables 35L (Locatif) et 35ST (STatique) décrite dans Boons et al. (1976b) (p. 216 et 235) est N0 V Loc N1. Pour la table 35L, le N1 est interprété comme un lieu source et/ou destination (Le bateau s'enfonce dans les flots), alors que dans la table 35ST sont regroupés les emplois statiques (Le pieu sort de l'eau). Le complément Loc N1 de la table 35L correspond donc à un complément interprété comme une source, que l'on note N1, ou un complément interprété comme une destination, noté N2, ou les deux en même temps. Cela pose problème pour savoir à quel complément font référence les propriétés codées dans la table, puisque la construction de base n'en contient qu'un seul. C'est pourquoi nous avons divisé la table 35L en cinq tables :

- 35L (Locatif) avec comme construction de base
 N0 V Loc N1 source Loc N2 destination, reconnaissant :

Paul a bondi du tabouret sur la table

Paul a bondi du tabouret

Paul a bondi sur la table

Ici, les deux compléments sont acceptés ensemble ou chacun séparément. Cela est codé dans la table par les deux constructions N0 V Loc N1 source et N0 V Loc N2 destination. Ce qui permet de déterminer les sources dépendantes, où seule la destination peut apparaître isolément, comme dans :

Max chemine de chez lui vers Gap

\*Max chemine de chez lui

Max chemine vers Gap; De plus, nous avons ajouté les deux propriétés définitoires N1 lieu source de N0 et N2 lieu de destination de N0.

- 35LS (Locatif Source) avec comme construction de base N0 V Loc N1 source, c'està-dire ne reconnaissant pas de destination (*Le train a déraillé de la voie*). De plus, la préposition *de* étant toujours possible, la propriété Loc N1 =: de N1 source est définitoire. Nous avons ajouté la propriété définitoire N1 lieu de destination de N0;
- 35LD (Locatif Destination) avec comme construction de base
   N0 V Loc N1 destination, c'est-à-dire ne reconnaissant pas de source (*Le bateau s'enfonce dans les flots*). Nous avons ajouté la propriété définitoire N1 lieu source de N0;
- 35ST (locatif STatique) avec comme construction de base N0 V Loc N1, N1 étant le lieu statique de N0. Cette table rassemble les emplois statiques des verbes de mouvement (*Le pieu sort de l'eau*, où le pieu ne bouge pas) ou des verbes sans mouvement (*Max habite à Paris*). Nous avons ajouté la propriété définitoire N1 lieu statique de N0;
- 35LR (Locatif Résiduel) avec comme construction de base N0 V Loc N1. Cette table concerne les mouvements internes à un lieu sans déplacement (Max appuie sur le bouton). Nous avons ajouté la propriété définitoire N1 = où, signifiant que l'objet N1 répond à la question en où? sans être le lieu de N0 (Où le livre est-il paru? Il

<sup>7.</sup> Nous avons réalisé ce travail en collaboration avec Christian Leclère en 2010 (Tolone et al., 2010).

est paru chez Plon). Le fait de distinguer les locatifs résiduels a fait changer de table la moitié des entrées de la table 35ST.

La construction de base de la table 38LH (Locatif à corrélat Humain) décrite dans Guillet et Leclère (1992) (p. 123 et 202) est N0 V N1 Loc N2, avec N1 =: Nhum obligatoire (et donc N1 =: N-hum codée -), et dont le N2 est interprété comme un lieu source et/ou destination (On a viré Max de son poste). Les prépositions locatives sont codées dans la table : de ou une autre préposition (Loc # de) pour l'argument source et dans, sur, contre, à ou vers pour l'argument destination. De même que pour la table 35L, si l'on note N2 le complément interprété comme une source et N3 celui interprété comme une destination, l'un, l'autre ou les deux peuvent apparaître, ce qui est contradictoire avec la construction de base. Nous avons donc divisé la table 38LH en quatre tables :

- 38LH (Locatif à corrélat Humain) avec comme construction de base N0 V N1 Loc N2 source Loc N3 destination, avec N1 =: Nhum obligatoire, qui accepte les deux compléments ensemble (Le général a replié ses soldats du champs de bataille sur leurs lignes). De plus, nous avons ajouté les deux propriétés définitoires N2 lieu source de N1 et N3 lieu de destination de N1. La table code également les deux constructions N0 V N1 Loc N2 source et N0 V N1 Loc N3 destination, permettant d'accepter chacun des compléments séparément :

Le général a replié ses soldats du champs de bataille

Le général a replié ses soldats sur leurs lignes

Cela permet de déterminer les sources dépendantes, comme dans :

Max conduit Ida de la chambre au salon

\*Max conduit Ida de la chambre

Max conduit Ida au salon;

- 38LHS (Locatif Source à corrélat Humain) avec comme construction de base
   N0 V N1 Loc N2 source, avec N1 =: Nhum obligatoire, et N2 lieu source de N1 (sans destination : On a viré Max de son poste);
- 38LHD (Locatif Destination à corrélat Humain) avec comme construction de base N0 V N1 Loc N2 destination, avec N1 =: Nhum obligatoire, et
   N2 lieu de destination de N1 (sans source : Max a engagé son fils dans la mairie);
- 38LHR (Locatif Résiduel à corrélat Humain) avec comme construction de base
   N0 V N1 Loc N1, avec N1 =: Nhum obligatoire, et N2 lieu statique de N1, concernant les mouvements internes à un lieu (Max sème Ida dans le métro).

# 6.2.4 Classes non publiées

Même si ces classes n'ont jamais été publiées, leur construction de base est décrite dans l'inventaire de Leclère (1990) et sur le site http://infolingu.univ-mlv.fr/ (Données Linguistiques > Lexique-Grammaire > Visualisation).

La construction de base de la table 36S (Symétrique), décrite également dans Borillo (1971), est N0 V N1 (avec+à) N2 ou N0 V N1 (d'avec+de) N2, mais aussi N0 V N1 et N2 en relation de paraphrase (Le maire a marié Paul (avec+à+et) Marie / On a dissocié Paul (d'avec+de+et) Luc). Les colonnes Prép2 =: a, Prép2 =: de, Prép2 =: avec et

Prép2 =: d'avec étant codées dans la table, nous avons noté la construction de base simplement N0 V N1 Prép N2 et la deuxième construction définitoire N0 V N1 et N2.

La construction de base de la table 35RR (Résiduel double) est N0 V Prép N1 Prép N2 ( $Paul\ rivalise\ d'astuce\ avec\ Jean$ ). Cette table n'a été décrite dans aucun livre et ses intitulés sont en cours d'élaboration. Notons que la préposition est toujours différente de à et de la préposition vide (<E>), la propriété Prép2 =: à est donc codée -.

La construction de base de la table 38RR (Résiduel double) est N0 V N1 Prép N2 Prép N3 (Paul offre de l'argent à Luc pour ce travail). Cette table est résiduelle par rapport à la table 38L, car elle n'accepte pas les deux propriétés N2 lieu source de N1 et N3 lieu de destination de N1 en même temps. Les deux prépositions sont codées dans la table (à, en, de, avec, contre, pour ou auprès de pour la préposition 2 et de, à, avec, par, pour, contre, comme, dans, en ou sur pour la préposition 3), même si la plupart ne pas encore codées (codage ~).

## 6.2.5 Ajout de classe

La table 32D (Disparition) a été créée parallèlement à la table 32A (cf. 6.2.2) même si elle comporte peu d'entrées. L'objet N1 est interprété comme disparaissant au cours du procès (Max a démoli la maison). Sa construction de base est N0 V N1, avec N1 disparition. Nous avons ajouté la propriété définitoire [passif par]. La liste des entrées codées dans cette classe est actuellement : anéantir, démolir, détruire, fusiller, sacrifier, souffler, supprimer, volatiliser.

# 6.2.6 Ajout d'intitulé

La construction de base de la table 38L0 (Locatif en position N0) décrite dans Guillet et Leclère (1992) (p. 123 et 193) est N0 V N1 (Max conserve son chapeau (E+sur la tête)). Nous avons ajouté la propriété définitoire N1 =: N-hum. Le sujet est un lieu, ce qui est codé dans la table par les colonnes N0 lieu source de N1 et N0 lieu de destination de N1, lorsque le verbe a un sens de mouvement, et n'est pas codé dans le cas où le verbe a un sens statique (propriété N0 lieu statique de N1 qui reste à coder). Nous avons ajouté la colonne N0 V N1 Loc N2 dans la table pour coder la possibilité de rajouter un complément locatif.

#### 6.2.7 Reste des classes

Les classes suivantes n'ont pas subi de modification dans leur construction de base, mais nous l'avons ajoutée à la table des classes.

Nous décrivons les classes de constructions transitives qui n'ont pas été décrites précédemment et dont les pages citées correspondent à la description de la construction de base dans Boons et al. (1976a), les classes de constructions intransitives décrites dans Boons et al. (1976b), ainsi que les classes de constructions transitives locatives décrites dans Guillet et Leclère (1992).

#### Classes de constructions transitives

La construction de base de la table 36R (Résiduel) est N0 V N1 à N2 (p. 58) (Max attache une signification à ce geste). Cette table est résiduelle car les compléments à N2 ne correspondent pas à ceux qui permettent de définir de grandes classes d'emplois (comme les datifs, symétriques ou locatifs).

La construction de base de la table 38R (Résiduel) est N0 V N1 Prép N2 (p. 9 et 60) (Jean commence son discours par une citation), où la Prép2 est variable, elle est donc codée dans la table. Notons que la préposition est toujours différente de  $\grave{a}$ , la propriété Prép2 =:  $\grave{a}$  est donc codée -.

La construction de base de la table 39 est N0 V N1 N2 (p. 62) (On a élue Marie présidente).

La construction de base de la table 32NM (NuMérique) est N0 V N1, avec passif interdit (p. 73), les deux propriétés [passif par] et [passif de] sont donc codées — (Ce livre comprend dix chapitres).

La construction de base de la table 32H (Humain) est N0 V N1, avec N1 =: Nhum obligatoire (p. 75) (Le bruit a abasourdi Max).

La construction de base de la table 32R3 (Résiduel semi-figé) est N0 V N1 (p. 81) (Luc occupe (un poste+une charge+un emploi)). Nous avons ajouté la propriété définitoire [passif par]. Cette table code une colonne intitulée thèmeN1, contenant le classifieur de la petite classe restreinte des noms qui peuvent occuper la position objet direct pour l'emploi concerné (par exemple, ici fonction). L'unité sémantique et syntaxique semble être le couple V N1 plutôt que V lui-même, et une solution serait de classer ces emploi dans les constructions à verbe support.

#### Classes de constructions intransitives

La construction de base de la table 35R (Résiduel) est N0 V Prép N1 (p. 253) (Max a collaboré avec l'occupant). Un grand nombre de prépositions sont possibles, elles sont codées dans la colonne Prép1. Il s'agit d'une table résiduelle qui n'a pas de propriété définitoire comme les autres tables (symétriques, locatifs, complétives). Elle contient une colonne intitulée thèmeN1 qui restreint le N1 (par exemple, ici ennemi).

La construction de base de la table 33 est N0 V à N1 (complément non locatif) (p. 252) (Le caporal s'est rendu à l'ennemi, cf. Fig. 3.1). Il s'agit d'une table résiduelle par rapport aux tables 1, 5 et 7 admettant des complétives (sujet pour la table 5, en N1 pour la table 7) ou des infinitives (en N1 pour la table 1).

La construction de base de la table 31R (Résiduel) est N0 V, avec N0 =: N-hum (La route dérape), puisque si N0 =: Nhum est obligatoire, l'entrée figure dans la table 31H (p. 262). C'est une table résiduelle car les compléments ne sont pas homogènes, dont le sujet, qui n'est pas systématiquement contraint.

La construction de base de la table 31H (sujet Humain) est N0 V, avec N0 =: Nhum (p. 259) (Max déambule (E+dans la maison)). La propriété distributionnelle N0 =: Nhum est obligatoire, même si la colonne N0 =: N-hum métaphore est codée dans la table pour permettre de reconnaître une phrase métaphorique (Son imagination déambulait li-

brement). Certains compléments non essentiels, mais caractéristiques pour certains verbes, ont été codés grâce aux colonnes N0 V vers N ( $Paul\ titube\ (E+vers\ la\ porte)$ ) et N0hum V W sur ce point ( $Paul\ se\ goure\ (E+sur\ ce\ point)$ ).

#### Classes de constructions transitives locatives

La construction de base de la table 38L1 (Locatif en position N1) est N0 V N1 (p. 123 et 214) (*L'avion survole le pays*). Nous avons ajouté la propriété définitoire N1 =: N-hum. L'objet N1 est interprété comme un lieu, ce qui est codé dans la table par les colonnes N1 lieu de destination de N0, N1 lieu source de N0, N1 lieu statique de N0, N1 lieu de passage de N0 lorsque le verbe est un verbe de mouvement (codage + pour la colonne V mouvement), ou par la colonne V statique dans le cas contraire.

# 6.3 Les classes des noms prédicatifs

Les classes des noms prédicatifs (cf. Tab. 5.1(b)) sont au nombre de 78 (ou 83 si l'on tient compte des tables de L. Pivaut). Les verbes supports sont principalement *avoir*, dont 29 classes sont concernées, et *faire*, dont 37 classes sont concernées (ou 42 si l'on tient compte des tables de L. Pivaut), même si d'autres verbes supports peuvent être codés dans les tables.

Nous allons détailler les modifications apportées aux constructions de base, comme nous l'avons fait dans Tolone *et al.* (2010). La plupart des modifications concernent la définition de la construction de base elle-même. Nous avons noté dans toutes les constructions, l'entrée nominale Det N, dont le nom est spécifié dans la colonne <ENT>N.

En ce qui concerne les noms, il est important de remarquer que les exemples sont absents des tables. Nous avons ajouté certains exemples qui figurait sur des fiches cartonnées <sup>8</sup>. Mais ces fiches étant loin d'être complètes, la plupart des noms figurent dans les tables sans savoir dans quel sens ils sont utilisés, notamment lorsqu'il y a des doublons, où seul leur codage peut les différencier.

Nous commençons par certains noms ayant le verbe support *avoir* (6.3.1), puis le verbe support *faire* (6.3.2). Ensuite, nous abordons l'étude de quelques constructions converses avec différents verbes supports, où certaines entrées adjectivales et verbales figurent également (6.3.3). Enfin, nous présentons les nouvelles tables ayant été numérisées récemment (6.3.4).

# 6.3.1 Verbe support avoir

Nous présentons 4 classes de J. Giry-Schneider et A. Balibar-Mrabti, 2 classes de J. Giry-Schneider, ainsi que 7 classes de A. Meunier, toutes les classes se construisant avec le verbe support *avoir*.

<sup>8.</sup> Nous avons réalisé ce travail en collaboration avec Wankawee Puangkor en 2009.

#### Tables AN07 à AN10

Certaines classes avaient des colonnes codant la construction de base (par exemple, N0 avoir Det N) avec différents déterminants possibles (par exemple, N0 avoir un N et N0 avoir le N). La construction de base était donc redéfinie à chaque fois, tout en spécifiant la nature du déterminant. Nous avons enlevé cette information redondante, en définissant une seule fois la construction de base, et en indiquant dans les colonnes concernées uniquement la nature du déterminant.

Ainsi, pour la table AN09, nous avons renommé les trois colonnes N0 avoir un N, N0 avoir un certain N et N0 avoir des N respectivement en Det =: un, Det =: un-certain et Det =: des, la construction de base définie dans Giry-Schneider et Balibar-Mrabti (1993) (p. 27) étant N0 avoir Det N (Cette langue a un alphabet).

Le même procédé a été employé pour la table AN10 décrite dans Giry-Schneider et Balibar-Mrabti (1993) (p. 30) avec comme construction de base N0 avoir Det N (*Max a des absences*), mais également dans d'autre tables comme AN07, AN06, ANDN, F21 et ANA, qui seront vues par la suite.

En ce qui concerne la table AN07, sa propriété définitoire est décrite dans Giry-Schneider et Balibar-Mrabti (1993) (p. 10) par N0 avoir Det N (\*E+Modif), mais également la paraphrase N0 être de Det N (\*E+Modif). Elle reconnaît :

Ce monument a une architecture (\*E+simple)

= Ce monument est d'une architecture (\*E+simple)

Mais, pour les mêmes raisons que précédemment, il est préférable de séparer les informations concernant la nature du déterminant de celles définissant la construction. C'est pourquoi nous avons défini la construction de base par N0 avoir Det N, avec Det =: un-Modif. Cela nous a permis d'ajouter également la propriété définitoire Det =: un-certain, puisque le déterminant un certain est compatible avec toutes les entrées (Ce monument a une (\*E+certaine) architecture). La colonne N0 être de Det N Modif étant codée dans la table, il n'y a pas de deuxième construction définitoire. En effet, dans certains cas, cette construction ne s'applique pas :

Ce pays a une vieille culture

= \*Ce pays est d'une vieille culture

La propriété définitoire de la table AN08 est décrite dans Giry-Schneider et Balibar-Mrabti (1993) (p. 17) par N0 avoir Det N = il y avoir Det N Loc N0, en précisant que *avoir* admet les variantes *comporter* et *comprendre*. Elle reconnaît :

Cette question (a+comporte+comprend) plusieurs aspects

= Il y a plusieurs aspects dans cette question

La colonne il y avoir Det N Loc N0 étant codée dans la table, nous ne l'avons pas gardée en tant que construction de base, puisqu'elle n'est pas acceptée par toutes les entrées : Cette lanque (a+comporte+comprend) une écriture

= \*Il y a une écriture (dans+de) cette langue

Nous avons donc choisi d'avoir pour la table AN08 la construction de base N0 avoir Det N, avec les propriétés définitoires Vsup =: comporter et Vsup =: comprendre.

#### Tables ANSN et ANDN

La construction de base de la table ANSN est défini dans Giry-Schneider (2005b) (p. 220) par N0 avoir Det N (E+Qu P) sur N1 (Max a un préjugé sur les femmes). De plus, la colonne N0 avoir le N Qu P sur N1 est codée dans la table car elle n'est pas acceptée par toutes les entrées :

Max a sur les femmes le préjugé qu'elles conduisent mal

\*Max a sur les femmes la lacune qu'elles conduisent mal

C'est pourquoi la complétive ne doit pas figurer dans la construction de base, que nous avons notée N0 avoir Det N sur N1.

La construction de base de ANDN est défini dans Giry-Schneider (2005b) (p. 223) par N0 avoir Det N (de N1+Qu P) (Max a une approche scientifique de cette question). La complétive n'est possible que pour la moitié environ des noms (Jean a conscience de la présence de Marie = Jean a conscience que Marie est présente), nous avons donc également supprimé la complétive de la construction de base, notée N0 avoir Det N de N1.

#### Tables AN01 à AN06 et ANSY

Les tables AN01 à AN06 et ANSY de A. Meunier sont des nominalisations d'adjectifs avec le verbe support avoir. Ces 7 tables ont donc une double entrée : des adjectifs prédicatifs et leurs noms prédicatifs associés. Nous avons intégré ces tables dans les tables de noms prédicatifs, puisque c'est la seule catégorie réellement représentée jusqu'à présent. Ce qui nous a amené à intituler la colonne comportant l'entrée nominale <ENT>N, et la colonne comportant l'adjectif <OPT>Adj. Les propriétés définitoires concernent donc ces deux catégories, l'entrée nominale étant représentée par N et l'entrée adjectivale par Adj dans chacune des constructions concernées.

Trois constructions définitoires sont définies dans Meunier (1981) (p. 175) pour l'ensemble des tables (sauf la table AN06, cf. ci-dessous) :

N0 être Adj (E+Modif+Prép N1)

N0 avoir Det N (E+Modif+Prép N1)

N0 être de Det N (E+Modif+Prép N1)

Elles reconnaissent:

Jean est désinvolte

- = Jean a (une certaine+de la) désinvolture
- = Jean est d'une grande désinvolture

La construction de base adjectivale est la première et la construction de base nominale est la deuxième, avec *avoir* comme verbe support. C'est cette deuxième construction que nous retiendrons comme construction de base puisque nous considérons ici l'entrée nominale.

La table AN06 décrite dans Meunier (1981) (p. 205), se voit attribuer uniquement deux parmi les trois constructions définitoires précédentes :

```
N0 être Adj (E+Modif+Prép N1)
```

N0 avoir Det N (E+Modif+Prép N1)

\*N0 être de Det N (E+Modif+Prép N1)

Elle reconnaît:

Cette table est poussiéreuse

- = Cette table a de la poussière
- = \*Cette table est d'une certaine poussière

Le problème est que cette notation comporte deux signes + par construction, ce qui signifie par exemple, que la construction N0 avoir Det N (E+Modif+Prép N1) équivaut aux trois constructions N0 avoir Det N, N0 avoir Det N Modif et N0 avoir Det N Prép N1. Or, elles ne sont pas toutes les trois acceptées par toutes les tables. Nous aboutissons donc à neuf constructions à traiter au cas par cas. N'ayant pas d'informations supplémentaires sur les propriétés définitoires, nous avons dû faire des approximations, aussi exactes que possibles, pour rendre compte de toutes les colonnes, en gardant une certaine cohérence entre elles. Les choix peuvent être discutables, puisque la meilleure solution serait un remaniement complet des tables, les déterminants, modifieurs, etc. n'étant pas forcément les mêmes pour les trois constructions principales. Il importe de préciser que nous ne prenons pas en compte les trois constructions avec Modif, car lors de la spécification du déterminant un la présence obligatoire d'un modifieur est indiquée, par la propriété Det =: un-Modif. Cette colonne est codée dans toutes les tables, sauf AN03 et AN04 où nous l'avons définie comme définitoire.

Par défaut, nous avons donc les six constructions suivantes définitoires pour toutes les tables :

NO avoir Det N (construction de base possible)

N0 être de Det N

N0 être Adi

NO avoir Det N Prép N1 (construction de base possible)

N0 être de Det N Prép N1

N0 être Adj Prép N1

À présent, nous montrons l'étude faite pour chaque construction une par une pour définir pour chaque table, celles que nous avons réellement gardées comme définitoires <sup>9</sup>.

Une table nécessite un traitement spécifique, il s'agit de la table ANSY décrite dans Meunier (1981) (p. 202). Elle regroupe les paires à compléments symétriques, dont la définition implique qu'elles entrent dans les deux constructions suivantes :

N0 (être Adj+avoir Det N) Prép N1

= N0 et N1 (être Adj+avoir Det N)

Elle reconnaît :

Cet objet (est identique à+a une certaine identité avec) cet autre

= Cet objet et cet autre (sont identiques+ont une certaine identité)

Cela l'exclut de toutes les constructions sans Prép N1, et lui ajoute deux constructions définitoires supplémentaires :

N0 et N1 avoir Det N

N0 et N1 être Adj

<sup>9.</sup> Nous avons réalisé ce travail en collaboration avec Annie Meunier en 2010.

La construction de base est donc NO avoir Det N Prép N1 et les autres constructions définitoires sont NO être de Det N Prép N1, NO être Adj Prép N1, NO et N1 avoir Det N et NO et N1 être Adj.

Examinons le cas des trois constructions sans complément, la table ANSY étant exclue :

- la construction N0 avoir Det N est la construction de base pour toutes les tables à l'exception de la table AN06, où la colonne est codée dans cette table, ce qui pose problème car elle n'a aucune construction de base nominale et lorsque la colonne est codée -, cela signifie que seule l'entrée adjectivale compte. Cette propriété est également codée dans les tables AN01 et AN02, mais les entrées codées (par exemple, Léa a une grande fécondité) acceptent cette colonne au moins avec un modifieur, ce qui n'engendre aucun de problème puisque la colonne Det =: un-Modif est toujours codée + dans ces cas-là. C'est pourquoi, nous avons gardé N0 avoir Det N comme construction de base également pour les tables AN01 et AN02, elle l'est donc pour les tables AN01 à AN05;
- la construction N0 être de Det N n'existe pas car il y a obligatoirement un modifieur, elle est donc notée N0 être de Det N Modif (\*Luc est d'une bonté, à contraster avec Luc est d'une bonté rare). Cette construction est définitoire pour toutes les tables sauf pour AN06, qui est en fait une table de paires {N, N-a}, c'est-à-dire adjectivations de substantifs concrets. Cette table de paires {N, N-a} exclut la nominalisation N0 être de Det N Modif, qui n'est compatible qu'avec un N de caractère non comptable. Notons que c'est la seule construction que nous avons gardé avec la notation Modif, laquelle donne un sens à la colonne N0 être de Det N, qui est codée dans la table AN03, seule table acceptant parfois la construction sans le modifieur. La construction N0 être de Det N Modif est donc définitoire pour les tables AN01 à AN05;
- la construction N0 être Adj est le sujet même de la thèse de Meunier (1981), qui s'intitule *Nominalisation d'adjectifs par verbes supports*, elle ne figure donc dans aucune des tables et est définitoire des tables AN01 à AN06.

Voyons à présent les trois constructions avec le complément N1. Nous pouvons commencer par remarquer que la table AN04 contient les colonnes N0 avoir Det N pour N1 et N0 être Det N pour N1 (sans la préposition de) qui codent directement les constructions avec le complément N1 avec la préposition pour. De même, la table AN03, contenait la colonne Prép1 =: (avec+envers) que nous avons renommée et dupliquée en N0 avoir Det N (avec+envers) N1, N0 être de Det N (avec+envers) N1 et N0 être Adj (avec+envers) N1, afin de spécifier chaque construction complète avec les deux prépositions spécifiques, comme c'est le cas pour la table AN04. Cela justifie qu'il ne soit pas nécessaire d'établir de construction finissant par Prép N1 comme définitoire pour les autres tables, AN05 et AN06 ne faisant allusion à aucun complément dans leurs propriétés.

Les trois constructions avec le complément  ${\sf N1}$  ne concernent donc que les tables AN01, AN02 et ANSY :

- la construction N0 avoir Det N Prép N1 est la construction de base pour la table ANSY, comme nous l'avons évoqué précédemment. Elle contient la colonne

Prép1 (avoir Det N) codant la préposition associée à la construction, qui est codée pour toutes les entrées (sauf pour une entrée, mais cela a été corrigé). Ensuite, cette construction concerne les tables AN01 et AN02, ce qui se justifie par la présence de la colonne Prép1 codée dans la table. Le problème réside dans le fait que la préposition peut être vide et notée  $\langle E \rangle$ , or cette notation est incorrecte car elle ne signifie pas que l'on peut accepter le complément N1 sans préposition, mais qu'il n'y a pas de complément N1. Nous avons donc remplacé tous les  $\langle E \rangle$  par des -. Si l'on garde la construction définitoire N0 avoir Det N Prép N1, cela signifie que toutes les entrées acceptent un N1. C'est pourquoi nous l'avons ajoutée dans les tables AN01 et AN02 en la codant avec un + lorsqu'il y avait une préposition qui était codée et un - lorsqu'il n'y en avait pas. Cette construction n'est donc pas définitoire pour les tables AN01 et AN02:

- la construction N0 être de Det N Prép N1 est également définitoire de la table ANSY. Pour les tables AN01 et AN02, parallèlement à N0 avoir Det N Prép N1, la colonne a été ajoutée dans la table (avec le même codage que N0 avoir Det N Prép N1) et n'est donc pas définitoire des tables AN01 et AN02;
- la construction N0 être Adj Prép N1 ne figure pas explicitement, même si la préposition qui introduit le complément de la paire {Adj, Adj-n} (Adj-n désignant le nom issu de l'adjectif Adj) est codée. Mais par exemple, la conservation du complément pose souvent quelques problèmes. Nous savons que les paires à compléments sont regroupées en AN01 et AN02 et évidemment ANSY qui, par définition, a un complément symétrique du sujet. À défaut d'avoir plus d'information sur les tables AN01 et AN02, nous avons fait de même que pour N0 avoir Det N Prép N1 et N0 être de Det N Prép N1, nous avons ajouté la colonne N0 être Adj Prép N1 dans les tables, avec à nouveau le même codage (nous avons donc trois colonnes identiques), tout en sachant que les prépositions ne sont pas forcément exactes. En revanche, elle est définitoire de la table ANSY, sachant que les prépositions sont codées dans la table, puisqu'elle contient les deux colonnes Prép1 (être Adj) et Prép1 (avoir Det N). Cela permet de distinguer clairement les prépositions pour chacune des deux constructions.

Les trois constructions précédentes sont donc définitoires uniquement de la table ANSY. Nous devons également tenir compte des entrées d'adjectifs prédicatifs simples en tant qu'entrées supplémentaires sans oublier les constructions définitoires définies avec Adj, même si le codage est beaucoup plus complet pour les noms prédicatifs. Nous ferons le bilan de ces entrées dans la section 6.6.

# 6.3.2 Verbe support faire

Nous présentons 31 classes de J. Giry-Schneider, puis, 15 autres classes de J. Giry-Schneider, qui toutes se construisent avec le verbe support faire <sup>10</sup>.

<sup>10.</sup> Notons que la table F2B1 (contenant 65 entrées) est incluse dans la version 3.3 mais ne le sera pas dans la suivante puisqu'elle a été remplacée et annulée par la table FNDN. Cette dernière contient 136 entrées supplémentaires, mais 7 entrées ont également été supprimées (générique, mise en scène, scénario, squelette, tissu, toile de fond, trame) et ne figurent dans aucune autre table. De plus, même

#### Tables F1A à F91

Les tables F1A à F91 de J. Giry-Schneider, au nombre de 21, sont des nominalisations avec le verbe support *faire*, à partir des verbes déjà étudiés par M. Gross ou BGL, puisque leur classe est donnée dans les tables. Commençons par observer que cette colonne souffre d'un manque total de mise à jour, puisqu'elle ne tient pas compte de toutes les modifications récentes sur les verbes. En revanche, cela nous informe que ces verbes, dont la construction verbale est spécifiée, ne servent qu'à faire le lien avec les noms, mais ne sont en aucun cas à prendre en compte comme de nouvelles entrées verbales <sup>11</sup>. C'est pourquoi, nous ne détaillerons pas les modifications effectuées sur les constructions verbales, lesquelles font partie des constructions définitoires mais ne concernent pas les noms.

Toutes les constructions de base avec le verbe support *faire* sont définies dans Giry-Schneider (1978) (p. 28). Dans la majorité des cas, elles n'ont pas été modifiées, ou simplement séparées en plusieurs propriétés, ou encore simplifiées, car certaines colonnes sont codées dans la table :

- les tables F1A, F1B, F1C, F1D et F1R ont la construction de base N0 faire Det N
   (Max fait de la navigation);
- la table F6 a la construction de base N0 faire Det N de N1 Prép N2 (Luc fait le change de ses dollars (contre+pour) des marks);
- la table F8 a la construction de base N0 faire Det N Prép N1 Prép N2 (Max fait une enquête sur cette affaire auprès de Marie);
- les tables F4 et F41 ont la construction de base Nnr faire Det N à N1 (Max a fait peur à Ève). Dans un souci de réutilisabilité des intitulés, nous avons simplement renommé la construction de base N0 faire Det N à N1, avec N0 =: Nnr;
- les tables F9 et F91 ont la construction de base Nnr faire le N de N1 (Que Marie soit venue fait la surprise de Luc). De la même manière que précédemment, nous avons renommé la construction de base N0 faire Det N de N1, avec N0 =: Nnr et Det =: le;
- les tables F2A, F2B, F2B1, F2C et F2R ont la construction de base N0 faire Det N de N1 (E+à N2) (Max fait l'extraction d'une dent (E+à Léa)). Or, la colonne N0 faire Det N de N1 à N2 est codée dans la table car elle n'est pas acceptée par toutes les entrées (par exemple, Max fait l'épuration des eaux usées), c'est donc uniquement N0 faire Det N de N1 que nous avons gardé comme construction de base;
- les tables F3 et F31 ont la construction de base N0 faire Det N (à+contre) N1. Les deux colonnes Prép1 =: à et Prép1 =: contre étant codées dans la table, nous avons

si la construction de base est la même, on passe de 20 colonnes codées dans la table à 7 colonnes uniquement : on perd notamment des constructions telles que N0 faire Det N de N1 à N2, ou avec la forme pronominale se faire (N0 se faire Det N de N1), ou encore des informations sur les réductions en groupe nominal (GN =: le N de N0). Le même cas de figure se présente avec la table F31 (contenant 102 entrées), qui a été remplacée et annulée par FNAN, avec 171 entrées supplémentaires et 27 entrées supprimées. Parmi celles-ci, 11 seulement figurent dans d'autres tables de J. Giry-Schneider (baroud d'honneur dans FNANN, cuisine dans FN), ou de G. Gross (apothéose dans FR2, croc-en-jambe dans FS3). C'est la raison pour laquelle la version 3.3 contient l'ensemble des tables à notre disposition.

<sup>11.</sup> Ces entrées ne sont pas considérées comme des entrées supplémentaires, comme c'est le cas dans d'autres tables (voir 6.3.3).

adopté pour la construction de base plus générale : N0 faire Det N Prép N1. Cela permet de reconnaître des entrées telles que :

Max fait de la diffamation contre Léa

Max fait du baratin à Ève

Trois tables ont nécessité plus d'attention, car nous avons dû généraliser certains intitulés figurant dans ces tables, sinon la construction de base ne pouvait être acceptée par toutes les entrées.

La table F21 a la construction de base N0 faire Det N (de N1+Qu P) (E+à N2), ce qui donnerait les quatre propriétés suivantes : N0 faire Det N de N1, N0 faire Det N de N1 à N2, N0 faire Det N Qu P et N0 faire Det N Qu P à N2. Or, les colonnes Prép N1 =: Qu Pind et Prép N1 =: Qu Psubj sont codées dans la table et reconnaissent :

Max a fait (E+à Ida) la déclaration qu'elle viendra avec une surprise

Max fait (E+à Marie) le reproche qu'elle ne veuille pas lui écrire

Habituellement, nous remplaçons une préposition par Prép dans une construction, lorsqu'une ou plusieurs colonnes codent explicitement les différentes prépositions possibles. Dans cette table, seule la préposition de est possible, mais cette préposition est effacée en présence de la complétive. De plus, la notation de N1 dans la construction de base, ne permet pas de faire le lien direct entre Prép N1 et Qu P. Nous avons donc comme constructions définitoires N0 faire Det N Prép N1 à N2, avec Prép1 =: de, et N0 faire Det N Prép N1. Elles reconnaissent :

Max a fait une escroquerie d'une somme importante

Max a fait l'escroquerie d'une somme importante (E+à Léa)

Mais toutes les entrées n'acceptent pas un N2, comme l'entrée essai (Max fait l'essai de ce produit). Cela est en fait codé par la colonne N0 faire Det N à N2, puisqu'elle sousentend l'effacement possible de Prép N1, ainsi que la présence du complément N2. Étant le seul moyen de connaître les entrées acceptant un N2, nous avons dupliqué cette colonne pour coder de la même manière N0 faire Det N Prép N1 à N2. La construction de base est donc uniquement N0 faire Det N Prép N1.

La table F5 a la construction de base N0 faire Det N Prép N1 (E+de N2) où  $Prép =: \grave{a} + dans + sur$ . Les prépositions sont bien codées dans la table, il est inutile de les préciser. Un exemple reconnu par cette table est :

Paul fait des broderies sur cette nappe (E+de jolies petites fleurs)

Ce cas est assez rare, et la majorité des entrées n'acceptent pas de N2 (*Max fait des éclaboussures sur le sol*). C'est la colonne N0 faire un N Prép N1 de N2 qui code la présence du N2, même si le déterminant n'est pas obligatoirement *un*, comme cela est indiqué dans la construction (cf. exemple de l'entrée *broderie*). De plus, les déterminants sont codés indépendamment des constructions (Det =: un, Det =: des, etc.). Nous avons donc renommé cette colonne N0 faire Det N Prép N1 de N2 et l'unique construction de base est N0 faire Det N Prép N1.

La table F7 a la construction de base N0 faire Det N entre N1 et N2 (Max fait une distinction entre le vrai et le faux). Or, cette colonne est codée dans la table, mais elle n'est pas toujours +. En effet, les constructions peuvent avoir des formes variées selon les verbes considérés (Giry-Schneider, 1978) (p. 246), il y a ainsi parfois plusieurs formes

pour un même verbe:

Jean fait le mélange du beurre avec la farine

Jean fait le mélange du beurre et de la farine

On peut ainsi dénombrer cinq constructions distinctes étant codées dans la table :

N0 faire Det N de N1 avec N2

N0 faire Det N de N1 et de N2

N0 faire Det N entre N1 et N2

N0 faire Det N de N1 et N2 entre eux

N0 faire Det N de N1 à N2

Il y a trop de disparités pour diviser la table et les noms n'acceptant pas la construction N0 faire Det N entre N1 et N2 sont discutables (par exemple, addition, alliage, substitution, etc.). C'est pourquoi, N0 faire Det N entre N1 et N2 reste la construction de base. Il faut souligner le fait que cette généralisation a été faite afin de pouvoir faire la conversion au format Lefff (voir section 8.1) qui nécessite une construction de base pour chaque table.

#### Tables FN à FNPNN

Les tables FN à FNPNN de J. Giry-Schneider sont des constructions nominales avec le verbe support *faire*, elles représentent 10 classes, et sont de trois sortes :

- celles se terminant par N : elles sont composées uniquement d'un nom (<ENT>N);
- celles se terminant par NA : elles sont composées d'un nom et d'un adjectif (<ENT>N
  et <ENT>Adj), dont l'ordre est interverti si la colonne Adj permut obl est codée +
  dans la table;
- celles se terminant par NN : elles sont composées d'un nom, d'une préposition, éventuellement d'un déterminant (souvent vide) et d'un deuxième nom (<ENT>N,
   ENT>Prép, <ENT>Detc et <ENT>Nc).

Elles sont ensuite divisées en quatre ensembles.

Pour commencer, examinons l'ensemble des tables dont le nom commence par FN dont la construction de base décrite dans Giry-Schneider (1987) (p. 97) est N0 faire Det N :

- table FN: Max fait des abdominaux;
- table FNA: Max a fait une faute professionnelle (Max a fait une bonne affaire, avec l'adjectif interverti);
- table FNN: Max a fait une erreur de jeunesse (Max fait la course contre la montre, avec un déterminant non vide).

Puis, observons l'ensemble des tables dont le nom commence par FNPN dont la construction de base décrite dans Giry-Schneider (1987) (p. 107) est N0 faire Det N (E+Prép N1), que nous avons simplement séparée en deux constructions : N0 faire Det N Prép N1 comme construction de base et N0 faire Det N comme deuxième construction définitoire :

- table FNPN: Luc a fait un colloque (E+sur ce thème);
- table FNPNA: Luc a fait une coupe sombre (E+dans son manuscrit);
- table FNPNN: Max a fait un article de fond (E+sur ce sujet).

Certains de ces noms composés sont déjà présents dans une autre table en tant que nom simple, par exemple article de fond (FNPNN) et article (FNPN). C'est pourquoi nous ne

pouvons pas considérer uniquement le premier nom de ces noms composés comme entrée de la table également, d'autant plus que, souvent, plusieurs noms composés commencent par le même nom simple, on aurait alors beaucoup de doublons de la même entrée. En revanche, tous les mots simples contenus dans les mots composées ne sont pas tous codés, par exemple erreur de jugement (FNPNN) alors que erreur n'est codé dans aucune table, il faudrait donc les ajouter. En effet, la phrase suivante est tout a fait acceptable : Max a fait une erreur (E+de jugement) sur cette affaire

Ensuite, considérons l'ensemble des tables dont le nom commence par FNAN dont la construction de base décrite dans Giry-Schneider (1987) (p. 125) est N0 faire Det N à N1, avec N0 =: Nhum et N1 =: Nhum obligatoires (et donc N0 =: N-hum et N1 =: N-hum codées -). Le complément N1 étant tout aussi facultatif que pour les tables FNPN, nous avons également ajouté la deuxième construction définitoire N0 faire Det N :

- table FNAN :  $Max fait un canular (E+\grave{a} Marie)$  (cf. Fig. 3.4);
- table FNANA : Max fait les yeux doux (E+à Marie);
- table FNANN : Léa a fait le coup de la panne (E+à Jean).

Enfin, la table FNDN a comme construction de base N0 faire Det N de N1 décrite dans Giry-Schneider (1987) (p. 133) (Max a fait la biographie de Luc). Pour cette table, le complément N1 est obligatoire. De plus, la colonne N0 faire un N, codée dans la table, permet de reconnaître certaines entrées avec un sens différent :

```
Max fait le film des événements (film = <récit>)
Max fait un film (film = <cinéma>)
```

#### 6.3.3 Constructions converses

Les tables AA à IS2 (ou plus exactement : AA, AD, DR1 à DRC, ES, FR1 à FR3, FS1 à FS3, IS1 et IS2) de G. Gross décrites dans Gross (1989) constituent 15 tables de noms prédicatifs avec des constructions converses entre deux verbes supports qui varient en fonction des tables.

Les tables DR1, DR2 et DR3 (Donner-Recevoir) ont N0 donner Det N à N1 comme construction de base et N1 recevoir Det N de (E+la part de) N0 comme construction converse (p. 57, 129, 189, 216). Nous avons renommé cette deuxième construction définitoire en N1 recevoir Det N (de+de la part de) N0, pour identifier correctement les deux prépositions qui peuvent être de ou de la part de. Cette notation a été changée pour l'ensemble des tables. Illustrons ces deux constructions :

Max a donné (une+des+quelques) claque(s) à Luc

 $= Luc \ a \ reçu \ (une+des+quelques) \ claque(s) \ (de+de \ la \ part \ de) \ Max$ 

La table DR1 contient des nominalisations à partir de verbes, dont l'entrée nominale liée morphologiquement est notée <ENT>N et l'entrée verbale <OPT>V :

Luc a ordonné à Max de se taire

= Luc a donné l'ordre à Max de se taire

Remarquons que le deuxième complément est identique dans la construction verbale et dans la construction à verbe support, mais qu'aucune des deux n'est codée dans la table. Notons également que ces verbes ne sont pas obligatoirement présents dans les tables de verbes, car ils sont d'un usage assez ou relativement rare, comme par exemple le verbe

semoncer associé au nom semonce (table DR1), qui signifie réprimander. Le problème réside dans le fait qu'il n'est pas possible d'établir une construction de base verbale, car elle peut être intransitive ou transitive en fonction des entrées, comme par exemple (en opposition à l'entrée ordonner):

Luc a appuyé ce projet

= Luc a donné son appui à ce projet

Il faudrait donc coder les deux colonnes N0 V à N1 et N0 V N1 <sup>12</sup> dans la table pour les verbes absents des tables de verbes (ou encore mieux les ajouter en tant qu'entrées dans les tables de verbes pour les coder). Puis, pour les verbes présents, il faudrait faire référence à l'identifiant du verbe dans les tables de verbes et coder — (ou supprimer) les deux propriétés précédentes (ce qui permettrait de ne pas en tenir compte comme entrée verbale). Actuellement, afin de pouvoir tenir compte de ces nouvelles entrées verbales, les deux constructions sont temporairement considérées comme définitoires (on reconnaît donc des phrases agrammaticales). Cela a également été réalisé pour les tables FR1, FS1 et IS1.

La table DR2 comprend des noms prédicatifs non reliés à un verbe (p. 132), comme par exemple attention et la table DR3 contient les noms composés (p. 139), comme par exemple délégation de pouvoir dont l'entrée est entièrement contenue dans <ENT>N, contrairement aux tables FN à FNPNN de J. Giry-Schneider. D'autres verbes supports sont acceptés et sont codés dans la table, avec des propriétés telles que donner = accorder ou recevoir = avoir, faisant référence à la construction standard ou converse. La numérotation des tables a la même signification dans les tables suivantes : 1 pour déverbaux, 2 pour autonomes et 3 pour composés.

La table DRC (Donner-Recevoir un Coup) a N0 donner un coup de N à N1 comme construction de base et N1 recevoir un coup de N (de+de la part de) N0 comme construction converse (p. 151, 216):

Max a donné un coup de bâton à Luc

= Luc a reçu un coup de bâton (de+de la part de) Max

Cette table contient aussi bien des noms déverbaux (V-n) que des noms isolés (N), c'est-à-dire non reliés à un verbe. Ils se distinguent dans la table par la colonne < OPT>V contenant un verbe ou un - (comme par exemple, le nom  $b\hat{a}ton$  relié à  $b\hat{a}tonner$ , et le nom bambou non relié à un verbe). Ici, la construction verbale est toujours NOVN1, mais elles est codée dans la table uniquement lorsque le verbe est présent.

Les tables FR1, FR2 et FR3 (Faire-Recevoir) ont N0 faire Det N Prép N1 comme construction de base et N1 recevoir Det N de (E+la part de) N0 (p. 218) comme construction converse :

Max fait des flatteries à Léa (table FR1)

Léa reçoit des flatteries de la part de Max

Les entrées nominales de ces tables sont extraites des tables F1A à F91 de Giry-Schneider (1978) pour les noms reliés à un verbe (plus exactement, des tables F2, F3, F5 et F6 pour la table FR1) et des tables FN à FNPNN de Giry-Schneider (1987) pour les noms isolés (plus exactement, de la table FNAN pour la table FR2 et des tables FNDN, FNANA

<sup>12.</sup> Cela revient à accepter la disjonction de propriétés suivante : (N0 V à N1) ou (N0 V N1).

et FNANN pour la table FR3). Quelques noms ont été ajoutés dans chacune des tables. Par exemple, dans la table FR1, il y a des noms tels que *commande*, *exhortations*, *interdiction*, *menaces* et *obligation*. Dans la table FR2, contrairement à FNAN, des noms dont le complément peut être un nom non humain ont été ajoutés. Dans la table FR3, il y a également des noms composés nouveaux. La difficulté réside donc dans le fait de pouvoir les reconnaître pour pouvoir associer les entrées qui sont en double avec l'entrée originale des tables de J. Giry-Schneider.

Les tables FS1, FS2 et FS3 (Faire-Subir) ont N0 faire Det N Prép N1 comme construction de base et N1 subir Det N de (E+la part de) N0 comme construction converse (p. 262): Max a fait une contre-expertise de ce document (table FS3)

Ce document a subi une contre-expertise de la part de Max

Les tables IS1 et IS2 (Infliger-Subir) ont N0 infliger Det N à N1 comme construction de base et N1 subir Det N de (E+la part de) N0 comme construction converse (p. 282) :

Max a infligé une défaite à Luc (table IS2)

Luc a subi une défaite de la part de Max

L'effectif étant réduit, quelques noms composés ont été ajoutés à IS2.

La table ES (Exercer-Subir) a NO exercer Det N Prép N1 comme construction de base et N1 subir Det N (de+de la part de) NO comme construction converse (p. 285) :

Max exerce son arrogance contre Luc

Luc subit l'arrogance de Max

Les noms pouvant être des V-n, des N ou des Adj-n, les deux colonnes <OPT>V et <OPT>Adj figurent dans la table et peuvent être vides toutes les deux. Par exemple, le nom *attirance* est associé au verbe *attirer* et à l'adjectif *attirant*. Il faudrait vérifier que les verbes figurent bien tous dans les tables de verbes, et les adjectifs peuvent être utilisés pour créer des entrées adjectivales puisqu'il n'y a pas de tables d'adjectifs utilisables actuellement. De plus, les colonnes N0 V N1 et N0 être Adj Prép N1 sont codées lorsque le verbe et/ou l'adjectif sont présents.

La table AA (Avoir-Avoir) a N0 avoir Det N Prép N1 comme construction de base et N1 avoir Det N de N0 comme construction converse (p. 233) <sup>13</sup>. Les noms de cette table sont soit des nominalisations d'adjectifs extraits des tables AN01 à AN06 et ANSY de Meunier (1981), soit des noms isolés, ou soit des noms déverbaux correspondant pour la plupart du temps aux verbes de la table 12 (ou de la table 6) de Gross (1975). Les verbes et adjectifs n'étant pas codés dans la table, ils ne seront donc pas pris en compte. Il faudrait donc repérer quels sont les noms déjà codés dans les tables de A. Meunier pour pouvoir les fusionner en définissant une priorité d'une des deux constructions sur l'autre et en ajoutant des colonnes à la table correspondante.

Prenons un exemple, l'entrée bienveillance figure dans la table AA de G. Gross, mais est aussi dans la table AN03 de A. Meunier, et même également dans la table APE21 de Vivès (1983). Le sens est le même pour ces trois tables :

Max a une certaine bienveillance (pour+envers+à l'égard de) Luc

On peut observer des différences dans le codage des verbes supports, des déterminants

<sup>13.</sup> Pour la table AA, la construction converse au sens de Gross (1989) est analysée comme construction à opérateur à lien par Danlos (1988) (p. 27).

et des constructions inverses ou converses. Examinons l'exemple suivant, aussi complet que possible, illustrant les différentes propriétés de cette entrée, dans la table AA :

 $Max\ (a+ressent+\acute{e}prouve)\ (une\ grande+de\ la)\ bienveillance\ (pour+\grave{a}\ l'\acute{e}gard\ de)\ Luc$ 

Luc (a+est l'objet de+fait l'objet de) une grande bienveillance de Max

Dans la table AN03:

Max a (une grande+de la) bienveillance (avec+envers) Luc

Dans la table APE21:

Max a (la bienveillance de Luc+sa bienveillance)

Max perd ((la+une) bienveillance de Luc+sa bienveillance)

Luc a (une grande+de la) bienveillance pour Max

Luc perd toute bienveillance pour Max

Luc (est de+est sans) Det bienveillance pour  $Max^{14}$ 

Aucune entrée n'est complètement identique à l'autre, et les entrées nominales ne sont pas toutes pourvues d'exemple, ce qui permettrait d'identifier leur sens. Nous rencontrons donc un réel problème pour reconnaître que ces trois entrées sont à fusionner, sans pour autant savoir ensuite comment les fusionner.

La table AD (Avoir-Donner) a comme construction de base uniquement NO donner Det N à N1 (p. 27), qui est la construction la plus longue (avec un N1, permettant de faire le lien lorsqu'il passe en position sujet). La colonne N1 avoir Det N est codée dans la table :

Le visage de Marie a des rides

Le temps a donné des rides au visage de Marie

Le temps a ridé le visage de Marie

Les noms sont tous déverbaux et la colonne <OPT>V est codée, ils sont donc à garder. De plus, la colonne N0 V N1 est codée + pour toutes les entrées verbales.

On peut donc noter comme entrées supplémentaires, les adjectifs prédicatifs simples de la table ES, et les verbes simples des tables DR1, DRC, FR1, FS1, IS1, ES et AD n'étant pas déjà codés dans les tables verbales. Ces entrées, dont le nombre est donné dans la section 6.6, restent évidemment à vérifier pour éviter de créer trop de doublons. De plus, notons que dans les tables DRC, ES et AD, les constructions verbales et adjectivales sont codées. Elles ne sont pas définitoires, comme c'est le cas pour les tables AN01-AN06 et ANSY. Cela permet de les coder — lorsqu'aucun verbe ou adjectif n'est associé à l'entrée. Cependant, la construction verbale des tables DR1, FR1, FS1 et IS1 reste à coder selon les entrées, afin d'éviter d'accepter des constructions agrammaticales.

#### 6.3.4 Nouvelles classes

Considérons à présent les quatre ensembles de tables que nous avons numérisées récemment : 2 classes de D. de Négroni-Peyre avec le verbe support *être en*, 6 classes de

<sup>14.</sup> Notons que les déterminants possibles ne sont pas codés pour les deux constructions N1 être de Det N Prép N0 et N1 être sans Det N Prép N0, et que les déterminants acceptés par avoir et perdre dans les constructions converses ne semblent pas tous acceptables (une grande+de la+toute).

R. Vivès et 8 classes de J. Labelle avec le verbe support *avoir*, et 5 classes de L. Pivaut avec le verbe support *faire*.

#### Tables PSY et SYM

Les tables PSY et SYM de D. de Négroni-Peyre sont des nominalisations avec le verbe support être en, à partir des verbes déjà étudiés par M. Gross ou BGL puisque leur classe est donné dans les tables. C'est une étude des paires {V, V-n}, V-n que nous avons renommées N dans les constructions. D'ailleurs, le problème est que seules les entrées verbales sont codées dans la colonne <ENT>V (et non <OPT>V car pour le moment, il s'agit de l'entrée principale), alors que pour trouver le nom, seul le suffixe à ajouter au verbe est codé dans la colonne suffixe -n. Nous ne devons pas prendre en compte ces verbes comme de nouvelles entrées verbales, il faudrait donc écrire explicitement chaque nom afin de pouvoir les prendre en compte comme des noms prédicatifs <sup>15</sup>. De plus, ces tables sont décrites dans de Négroni-Peyre (1978) mais aucune construction de base n'est spécifiée. En effet, elles sont définies p. 136 comme étant les constructions psychologiques associées à la préposition devant pour la table PSY:

Marie rage devant ta méchanceté

= Marie est en rage devant ta méchanceté

Ainsi que les constructions *symétriques* qui mettent en jeu la préposition *avec* pour la table SYM :

Mic cohabite avec Flo

- = Mic et Flo cohabitent
- = Mic est en cohabitation avec Flo
- = Mic et Flo sont en cohabitation

Les différentes prépositions possibles sont codées dans les tables. Les relations entre verbes et noms sont décrites de la sorte (p. 131), en sachant que le verbe peut être pronominalisé en se V :

N0 V N1 = N0 être en N Prép N1

NO V Prép N1 = NO être en N Prép N1

N0 V N1 Prép N2 = N1 être en N Prép N2

La construction N0 être en N Prép N1 étant la seule effectivement partagée par les deux tables (le complément N2 ne concerne que les entrées de la table SYM ayant la colonne N0 V N1 avec N2 codée +), et ne variant que par sa préposition, nous l'avons établie comme définitoire des deux tables. Puis, nous avons renommé les colonnes de la table PSY: N0 être en N contre N1, N0 être en V-n après N1 et N0 être en V-n devant N1 en Prép1 =: contre, Prép1 =: après et Prép1 =: devant; ainsi que celles de la table SYM: N0 être en N avec N1, N0 être en N contre N1 et N0 être en N à N1 en Prép1 =: avec, Prép1 =: contre et Prép1 =: à. Pour la table SYM, nous avons également défini la construction définitoire N0 et N1 être en N pour rendre compte de la symétrie. Nous n'avons pas établi de constructions définitoires pour les verbes car les constructions verbales sont

<sup>15.</sup> Il faudrait saisir les noms comme cela a été fait par Eric Laporte pour les tables de nominalisation AN01 à AN06 et ANSY d'A. Meunier et F1A à F91 de J. Giry-Schneider, dans lesquels seul l'adjectif ou le verbe était en clair, comme on peut le voir dans les ouvrages originaux.

codées dans les tables.

#### Tables APE1 à APP3

Les tables APE1 à APP3 de R. Vivès décrites dans Vivès (1983) (p. 164) sont au nombre de 9. Par définition, les tables dont le nom commence par APE ont comme verbe support *avoir* et *perdre*, alors que les tables dont le nom commence par APP ont comme verbe support *avoir*, *perdre* et *prendre*. Les tables sont divisées en trois ensembles en fonction de la présence ou non de compléments :

les tables numérotées 1 n'ont aucun complément. La construction de base de la table
 APE1 est N0 (avoir+perdre) Det N :

Luc a de l'abnégation

Luc a perdu toute abnégation

Pour ne pas créer de nouveaux intitulés, nous avons réutilisé les intitulés déjà existants pour le verbe *avoir*, puis rajouté les autres verbes supports, et ceci pour toutes les constructions de base des tables. Pour la table APE1, la construction de base actuelle est donc N0 avoir Det N, avec Vsup =: perdre. De plus, il est spécifié p. 171 que pour l'ensemble de la table, *garder* et *conserver*, extensions aspectuelles de *avoir*, sont acceptées. C'est pourquoi nous avons ajouté les propriétés Vsup =: garder et Vsup =: conserver définitoires de la table.

Pour la table APP1, la construction de base est N0 avoir Det N, avec Vsup =: prendre et Vsup =: perdre :

Luc (a+prend) (de l'+un certain) allant

Luc a perdu tout allant

À cela s'ajoute la table APE11 qui accepte également N0 avoir Det N comme construction de base, avec Vsup =: perdre et N0 =: Nhum, le nom étant psychophysiologique :

 $Luc\ (a+a\ perdu)\ le\ (moral+forme);$ 

- les tables numérotées 2 ont un seul complément, que nous avons noté N1 et non N2 comme à l'origine, puisque le nom n'est pas compté comme premier complément dans l'ensemble des tables nominales. La construction de base de la table APE2 est donc N0 avoir Det N Prép N1, avec Vsup =: perdre, la préposition étant codée dans la colonne Prép1 :

Luc a des accès officiels auprès de Marie

Luc a perdu tout accès auprès de Marie

Celle admise par la table APP2 est N0 avoir Det N Prép N1, avec Vsup =: prendre et Vsup =: perdre :

Luc (a+prend) une certaine emprise sur (Marie+la vente du cuir)

Luc a perdu toute emprise sur (Marie+la vente du cuir)

Doit également être prise en compte la table APE21 qui a pour construction de base N0 avoir Det N de N1, avec Vsup =: perdre et N1 =: Nhum, mais aussi la construction *inverse*, ou plutôt converse, N1 avoir Det N pour N0 <sup>16</sup>, avec Vconv =: perdre, la notation Vconv désignant le verbe support converse, et permettant de différencier les

<sup>16.</sup> Nous n'avons pas gardé le terme de construction inverse employé dans Vivès (1983), malgré le

verbes supports de chaque construction <sup>17</sup>. Nous avons renommée cette construction définitoire N1 avoir Det N Prép N0 car la préposition Prép0 est codée lexicalement dans la table :

Luc (a+perd) l'estime de Max Max a de l'estime pour Luc Max perd toute estime pour Luc

N'oublions pas la table APE22 qui accepte cette même construction de base N0 avoir Det N de N1, avec Vsup =: perdre et N1 =: Nhum, mais également une construction *converse* qui n'est pas décrite et que nous avons définie par N1 Vconv Det N à N0, le verbe support converse Vconv étant codé dans la table par les quatre colonnes nommées Vconv =: accorder, Vconv =: adresser, Vconv =: donner et Vconv =: prêter :

Luc (a+perd) l'appui de Max

Max (donne+accorde) (un immense+son) appui à Luc

De plus, il est spécifié (p. 177) que les extensions aspectuelles garder et conserver sont régulières. Nous avons donc ajouté les propriétés Vconv =: garder et Vconv =: conserver définitoires de la table;

- les tables numérotées 3 ont également un seul complément mais celui-ci est facultatif, et cela pour toutes les entrées. La table APE3 a donc comme construction de base N0 avoir Det N (E+Prép N1), avec Vsup =: perdre. Afin de supprimer le +, nous avons séparé cette construction en deux constructions : N0 avoir Det N Prép N1 comme construction de base et N0 avoir Det N Prép N1 comme deuxième construction définitoire :

Luc a un certain acharnement (E+au travail)

Luc a perdu tout acharnement (E+au travail)

De même, la table APP3, accepte N0 avoir Det N Prép N1 comme construction de base et N0 avoir Det N comme construction définitoire (au lieu de N0 avoir Det N (E+Prép N1), avec Vsup =: prendre et Vsup =: perdre :

Luc (a+prend) un rôle important (E+dans la société)

Luc a perdu son rôle important (E+dans la société)

fait que les deux constructions soient inversées par rapport à celles de la table AA. Notons de plus que la table APE21 contient pratiquement les mêmes entrées que la table AA, il serait donc judicieux de garder la table AA en y ajoutant les informations de la table APE21. En effet, Gross (1989) ayant etudié toutes les converses du français, sa terminologie est plus cohérente avec ses autres classes.

17. Notons que pour les constructions converses des tables AD à IS2 de G. Gross, la notation Vconv n'est pas utilisée car les colonnes s'intitulent, par exemple pour la table IS2, infliger = administrer pour les verbes supports de la construction de base ou subir = écoper pour les verbes supports converses. Cependant, elle apparaît dans le lexique LGLex, au même titre que Vsup puisque cela permet d'avoir deux listes distinctes de verbes supports, chacune se référant à l'une des deux constructions. En réalité, toutes ces colonnes devraient être renommées de la même manière que la table APE21, car cela peut engendrer un problème pour les constructions converses telles que AA, dont il est difficile de voir que la propriété avoir = ressentir concerne le verbe support de la construction de base, alors que la propriété avoir = subir concerne le verbe support converse. La distinction se fait actuellement car les colonnes sont placées à droite pour les Vsup et à gauche pour les Vconv dans les tables et aucune n'est ambiguë.

#### Tables ANA à ANSU

Les tables ANA à ANSU (sauf ANDN et ANSN) de J. Labelle décrites dans Labelle (1974) (p. 14) sont des noms prédicatifs avec le verbe support *avoir*, c'est la raison pour laquelle les 8 tables commencent par AN (Avoir N).

La table ANS (Symétrique) a pour construction de base N0 avoir Det N avec N1 (p. 36) et la construction symétrique N0 et N1 avoir Det N (Max a eu une aventure avec Marie / Max et Marie ont eu une aventure). En réalité, le verbe support peut être avoir et/ou avoir eu, ce qui est codé par les deux colonnes Vsup =: avoir et Vsup =: avoir eu (l'exemple précédent, à contraster avec Max a une amitié avec Marie). C'est pourquoi nous avons renommé les deux constructions en N0 Vsup Det N avec N1 pour la construction de base, et N0 et N1 Vsup Det N pour la deuxième construction définitoire, le Vsup permettant de faire le lien avec les deux colonnes. Nous avons également renommé tous les verbes supports avoir en Vsup dans les constructions codées dans la table. Cela a également été fait pour l'ensemble des tables. Il est important de souligner que dans les autres tables de noms prédicatifs, la propriété Vsup =: avoir implique également Vsup =: avoir eu, puisque le verbe support peut être conjugué à tous les modes et à tous les temps. C'est pourquoi, lors de la conversion, la distinction entre avoir et avoir eu n'est pas faite pour le moment, même si elle est faite dans les tables ANA à ANSU.

La table ANA (constructions avec Prép =: à) a pour construction de base N0 avoir Det N à ce Qu P (p. 85), que nous avons renommée N0 Vsup Det N Prép N1, avec Prép1 =: à, car la préposition peut avoir d'autres valeurs (Ce liquide a une grande capacité (à+pour) se répandre / Ce vêtement a une bonne étanchéité (à+contre) la pluie). De plus, la complétive n'est pas obligatoire puisqu'elle est codée par les deux colonnes N1 =: Qu Pind et N1 =: Qu Psubj, qui peuvent être toutes les deux codées -. Le Vsup peut être ici avoir et/ou avoir eu, mais aussi manifester et/ou donner (Ce vêtement (a+manifeste+donne) une bonne étanchéité (à+contre) la pluie), même si le verbe avoir est codé + pour toutes les entrées. Le verbe avoir est d'ailleurs codé + pour toutes les entrées de la majorité des tables suivantes (sinon cela est précisé).

La table ANML (substantifs de Maladie avec complément Locatif) a pour construction de base N0 avoir Det Nmal Loc Npc (p. 121) qui provient en fait de deux constructions: N0 avoir Det N Loc Npc prévue pour la table ANML (Max a une éraflure au bras) et N0 avoir (mal+une éraflure) Loc Npc qui devait définir la table ANPC, mais qui n'existe pas. C'est pourquoi nous avons retenu N0 Vsup Det N Loc N1pc comme construction de base, après avoir numéroté le complément N1 pour faire le lien avec la préposition locative Loc1 codée dans la table. Nous avons également renommé le Nmal en N, car le fait que les entrées désignent des noms de maladie n'a pas besoin de figurer dans toutes les constructions, qui ont donc été toutes renommées. Ceci a été réalisé également pour les trois tables suivantes. D'autre part, la propriété sémantique N =: Nmal a été ajoutée comme propriété définitoire, afin de ne pas perdre cette information. Le problème de la table ANML réside dans le fait que la construction de base est également une colonne qui est codée dans la table sans être toujours codée +. N'ayant pas trouvé le sens de cette colonne, elle est ignorée pour accepter la construction de base pour toutes les entrées. Dans cette table et dans la suivante, le verbe avoir est également codé + pour toutes

les entrées, même si pour cela nous avons dû forcer certaines entrées qui n'acceptaient aucun verbe support.

La table ANM (substantifs de Maladie sans compléments locatif) a pour construction de base N0 avoir Det N (p. 121) (Nmal étant sous-entendu comme le témoignent les colonnes de la table) que nous avons renommée N0 Vsup Det N, avec  $N =: Nmal (Max \ a \ de \ la \ fièvre)$ .

La table ANMR (substantifs ne se construisant qu'avec avoir eu) a pour construction de base N0 avoir eu Det N (E+Loc Npc) (p. 121) (avec Nmal sous-entendu), que nous avons renommée N0 Vsup Det N, avec N =: Nmal (Max a eu un soufflet (E+sur la joue)). En effet, la colonne Loc N1pc code la possibilité d'ajouter un complément locatif à la construction de base. De plus, on avait la colonne Loc Npc =: <E> qui codait la facultativité de ce substantif, et qui avait le même codage que Loc N1pc (sauf pour une entrée sans que cela ne soit justifié). Cela signifie pour une entrée que, soit elle n'accepte pas de complément locatif, soit elle en accepte un mais qu'il est obligatoirement facultatif, ce qui justifie notre choix de mettre la construction de base sans locatif. La colonne Loc Npc =: <E> est donc ignorée puisque la facultativité est déjà codée dans la construction de base. Nous pouvons remarquer que la notation Vsup a été gardée pour être conforme aux autres tables, bien que Vsup =: avoir eu soit l'unique colonne figurant dans la table (elle est codée + pour toutes les entrées). De plus, la propriété Vsup =: avoir n'étant jamais acceptée, elle est codée -.

La table ANSU (constructions avec Prép =: sur) a pour construction de base N0 avoir Det N sur N1 (p. 156), que nous avons renommée N0 Vsup Det N sur N1 ( $Max\ a\ un\ certain\ ascendant\ sur\ Léa$ ). Les constructions codées dans la table contenaient également des Nmal alors que les entrées ne sont pas des noms de maladie (la propriété N =: Nmal n'est donc pas définitoire).

La table ANP (constructions avec Prép =: pour) a pour construction de base N0 avoir Det N pour N1 (p. 169), que nous avons renommée N0 Vsup Det N pour N1 (Marie a des dispositions pour la peinture). Dans cette table et la suivante, le Vsup est, soit avoir, soit avoir eu, sans faire l'unanimité. Nous avons dû forcer trois entrées de cette table qui n'avait aucun verbe support, à accepter le verbe avoir.

La table ANPR (constructions avec autres Prép) a pour construction de base N0 avoir Det N Prép N1 avec Prép!= avec+à+sur+pour (p. 177), que nous avons renommée N0 Vsup Det N Prép N1 (Max a une dent contre Luc). La préposition est codée par une des six colonnes Prép =: envers, Prép1 =: contre, Prép1 =: auprès de, Prép1 =: entre, Prép1 =: devant, Prép1 =: Loc. Nous considérons donc les quatre propriétés suivantes fausses pour l'ensemble des entrées : Prép1 =: avec, Prép1 =: à, Prép1 =: sur, Prép1 =: pour.

#### Tables FD1 à FD4

Les tables FD1 à FD4 de L. Pivaut <sup>18</sup> décrites dans (Pivaut, 1989) (p. 64) regroupent des noms prédicatifs avec le verbe support *faire*, qui se réfèrent à une activité musicale, sportive ou intellectuelle. Les tables sont au nombre de 5 et commencent par

<sup>18.</sup> Signalons que ces tables étant les dernières a avoir été numérisées, elles ne font pas partie de la version 3.3 mais seront incluses dans la suivante (Tolone, 2011).

FD (Faire Det N). La construction de base acceptée par les 5 tables est : N0 faire Det N (p. 1), avec N0 =: Nhum (p. 36) et Det =: du, faire = pratiquer (p. 45), qui signifie que lorsque le déterminant est partitif la valeur sémantique de la phrase est pratiquer (Max (fait+pratique) du sport de combat).

Au niveau syntaxique, les tables se distinguent par (p. 64):

- l'impossibilité de l'article indéfini un en position Det pour la table FD4 :  $Max\ fait\ (de\ l'a\acute{e}robic+*un\ a\acute{e}robic)$ 
  - Nous avons codé les deux propriétés Det =: un, faire = fabriquer et Det =: un, faire = pratiquer;
- l'impossibilité d'un adverbe de temps duratif quand un est sélectionné pour les tables FD2, FD3A et FD3B :
  - Max a fait (du football pendant un an+\*un football pendant un an) (table FD2) Nous avons ajouté la propriété Det =: un, Advtd (Advtd représentant un adverbe de temps duratif) en la codant pour les tables FD2, FD3A et FD3B, mais également FD4 alors qu'elle est codée + pour la table FD1. De plus, Dnum en position Det est très contraint, mais cette information n'est pas exploitable (codage O de la propriété Det =: Dnum);
- en plus du point précédent, le groupe nominal prédicatif contient toujours un déterminant numéral suivi d'une unité de distance pour les tables FD3A et FD3B :
   l'entrée est de la forme <ENT>Dnum <ENT>N (Max fait du cinq mille mètres) pour la table FD3A et <ENT>Dnum <ENT>N <ENT>Nc <ENT>Adjc (Max fait du cent mètres nage libre) pour la table FD3B (FD3A et FD3B ne représentent pas des différences de construction, mais des différences de morphologie des entrées);
- le fait que faire devient synonyme de fabriquer, faire apparaît comme une extension aspectuelle de avoir, avoir un est substituable à faire un et Dnum est partout possible en position Det pour la table FD1:

Max fait du piano / Max (fait+fabrique+a) (un piano+dix pianos)

Nous avons codé + les propriétés Det =: un, faire = fabriquer et Det =: un-Modif, faire = fabriquer alors que les propriétés Det =: un, faire = pratiquer et Det =: un-Modif, faire = pratiquer sont codées -. Nous avons ajouté la propriété Det =: un, faire = avoir en la codant + pour la table FD1 et - pour les autres. Enfin, nous avons codé + la propriété Det =: Dnum.

Cela peut se résumer par le fait que si l'ensemble des propriétés suivantes est vérifié, il s'agit d'une entrée de la table FD1 :

```
Det =: un, faire = fabriquer
```

Det =: un-Modif, faire = fabriquer

Det =: un, faire = avoir

 $\mathsf{Det} =: \mathsf{Dnum}$ 

Det =: un, Advtd

Si cet ensemble de propriétés est accepté, c'est une entrée des tables FD2, FD3A ou FD3B :

Det =: un, faire = pratiquer

Det =: un-Modif, faire = pratiquer

Si aucune des propriétés mentionnées n'est acceptée, l'entrée figure dans la table FD4.

# 6.4 Les classes des expressions figées

Les classes des expressions figées (cf. Tab. 5.1(c)) sont principalement celles de Gross (1982, 1988, 1996), elles sont au nombre de 54 (en incluant les 4 qui n'ont jamais été publiées). Nous expliquons comment nous avons procédé pour définir leurs constructions de base (6.4.1), comme nous l'avons fait dans Tolone et al. (2010). De même, celles de Giry-Schneider (1987) sont détaillées (6.4.2). À la suite de quoi nous nous penchons sur le cas de la classe de verbes 31I qui auparavant n'était pas considérée comme figée (6.4.3), et nous terminons par les constructions en être Prép X étudiées par Danlos (1980) (6.4.4).

### 6.4.1 Classes d'expressions figées de M. Gross

Chaque classe correspond à une classe morpho-syntaxique des expressions figées (Gross, 1982), le découpage a donc été fait en fonction de la structure de l'expression figée. Ensuite, les intitulés des différentes colonnes qui codent les mots de l'entrée figée correspondent à cette structure.

Nous avons défini chaque construction de base en incluant cette structure dans la phrase, c'est-à-dire en ajoutant le verbe et les arguments libres qui ne sont pas inclus dans l'expression figée <sup>19</sup>. Nous avons gardé la notation N0, N1 et N2 pour les arguments libres, et nous avons utilisé la notation C0, C1 et C2 pour les substantifs figés inclus dans la structure d'un argument figé tel que par exemple, Det1 C1 dans la construction N0 V Prép1 Det1 C1 Prép2 N2.

Cette construction est la construction de base que nous avons défini pour la table CPQ. Cela signifie que le sujet est libre, le verbe est figé, le premier complément est figé (avec pour structure Det1 C1) et introduit par une préposition figée, le deuxième complément est libre et introduit par une préposition figée (par exemple, l'entrée aboutir à la conclusion de).

Si l'on prend par exemple la table EPCPN, la construction de base est N0 être Prép1 Det1 C1 Prép2 N2 (être à la frontière entre). Dans cette expression, le second complément libre Prép2 N2 est forcément complexe (Sartre est à la frontière entre la dépression et le génie) ou pluriel obligatoire (Bénazet est à la frontière entre les deux nations). Le verbe être n'est pas figé, il est support car il peut s'effacer (cf. section 3.2):

Je connais quelqu'un qui est à la frontière entre la dépression et le génie = Je connais quelqu'un à la frontière entre la dépression et le génie

<sup>19.</sup> Nous avons réalisé ce travail en collaboration avec Stavroula Voyatzi en 2009 (Tolone et al., 2010).

En revanche, la négation éventuelle est figée, car elle ne s'efface pas. C'est pourquoi, nous spécifions le verbe support  $\hat{e}tre$  dans le lexique LGLex, comme pour les tables de noms prédicatifs.

Dans chaque table, il y a une colonne pour chaque mot faisant partie de l'expression figée. Toutes les colonnes ont été renommées pour correspondre à la construction de base. Pour la table vu précédemment (EPCPN), on a <ENT>Ppv (qui correspond au codage des colonnes Ppv =: en figé et Ppv =: Neg), <ENT><être>, <ENT>Prép1, <ENT>Det1, <ENT>C1 et <ENT>Prép2. Notons que la colonne <ENT><être> permet de coder le verbe être, mais, par exemple, également l'adverbe négatif pas. Il est en effet indiqué dans l'entrée verbale, comme pour les tables de verbes, lorsque la colonne <ENT>Ppv est codée ne ou n', la colonne Ppv =: Neg est codée +, et que l'adverbe est contraint, ce qui est toujours le cas dans les expressions figées. Notons que les pronoms clitiques et les adverbes figés avec le verbe sont inclus dans l'entrée verbale de la construction de base (c'est-à-dire être, V, etc.), c'est pourquoi Ppv ne figure jamais parmi les constituants de la construction de base. Puis, on a des propriétés distributionnelles sur les arguments libres, telles que N0 =: Nhum, N0 =: N-hum et N0 =: Qu P pour le sujet, ainsi que N2 =: Nhum et N2 =: N-hum pour le second complément libre.

Notons que la notation  $\langle E \rangle$  est utilisée pour toute catégorie n'apparaissant pas dans l'entrée, comme par exemple pour l'entrée être en  $\langle E \rangle$  flirt avec 20. Mais il faut surtout préciser que les différents intitulés correspondant aux différentes zones figées des expressions sont approximatifs. En effet, d'une part, les structures sont tellement variées que si l'on voulait donner aux zones des intitulés exacts, cela produirait une multitude de classes minuscules. D'autre part, si l'on supprimait complètement les intitulés, cela gênerait le codage manuel des nouvelles entrées. Ces intitulés approximatifs rendent donc la formalisation exacte très délicate (actuellement, seule l'entrée complète est gardée). En effet, les mots de l'entrée ne correspondent pas toujours à la catégorie syntaxique indiquée par l'intitulé de la colonne, mais ils peuvent appartenir à une autre catégorie ou à une combinaison de plusieurs catégories.

Par exemple, l'entrée être dans de bonnes dispositions envers figure également dans la table EPCPN, sans y avoir ajouté une colonne <ENT>Adj1. C'est donc la colonne <ENT>Det1 qui contient le déterminant et l'adjectif de bonnes. Ajouter une colonne peut paraître simple, mais il a fallu limiter le nombre de colonnes pour des raisons de lisibilité. Par exemple, la table CPP contient les colonnes <ENT>V, <ENT>Prép1, <ENT>Det1, <ENT>C1, <ENT>Prép2, <ENT>Det2 et <ENT>C2, ce qui permet d'y insérer, sans que cela pose problème, l'entrée répondre à la force par la force. Mais cette table contient également l'entrée vivre de <E> amour et de <E> eau fraîche où la colonne <ENT>Prép2 contient la conjonction et la préposition et de, l'entrée tomber sur plus fort que <E> Lui-0, où la colonne <ENT>Prép1 contient l'adverbe plus et la colonne <ENT>Prép2 contient la conjonction de subordination que, et l'entrée tirer sur la corde jusqu'à ce

<sup>20.</sup> Afin de pouvoir mettre en relation les entrées avec la structure de l'expression figée, nous noterons <E> chaque catégorie vide pour chaque entrée, sauf lorsqu'il s'agit de la colonne <ENT>Ppv puisqu'elle ne figure pas dans la construction de base.

qu'elle casse, où la colonne <ENT>Det2 contient le ce de la complétive, tandis que la colonne <ENT>C1 contient la complétive qu'elle casse.

Sans compter les expressions figées adjectivales dont nous avons déjà parlé (avec le verbe support être et un sujet libre), les autres classes d'expressions figées sont verbales, sauf la table C0E qui rassemble les expressions figées de diverses catégories empoyées en tant que phrases. Elle contient des verbes à l'impératif (<E><E><E> sauve <E> qui peut!<E>), des noms (<E> au (=à le)  $^{21}$  le plaisir de vous revoir!<E>), des adverbes (<E><E> <E> prochainement sur vos écrans <E>), des pronoms interrogatifs (<E> à <E> quoi <E> <E> bon ? <E>), etc. Sa construction de base a été définie par Conj Prép0 Det0 C0 Prép1 (Det1 C1+N1) Prép2 N2. Par exemple, pour l'entrée sauve qui peut!, le C0 correspond à sauve, le Det1 correspond à qui et le N1 correspond à peut!. Notons que la colonne <ENT>Ppv figure également dans cette table mais est vide pour toutes les entrées sauf une : ne pas <E> se pencher au dehors <E>. Elle contient donc le pronom clitique ne figé avec le verbe comme dans les autres tables, puisque le C0 correspond au verbe pronominal à l'infinitif se pencher  $^{22}$ .

Voyons à présent le cas des trois tables avec le verbe *être* et un sujet figé : EC0, E0P1 et E01. Elles ont les constructions de base suivantes :

- la table EC0 : Ce être Prép1 Det1 C1 Prép2 Det2 C2 (c'être <E> du beau <E> <E>) ;
- la table E01 : Det0 C0 être Adj1 (l'agonie être lente);
- la table E0P1 : Det0 C0 être Prép1 Det1 C1 (les actions être en baisse et les actions être en hausse).

Pour la table EC0, son sujet figé est ce ou c', après avoir codé cette variante dans la colonne  $\langle \mathsf{ENT} \rangle \mathsf{Ce}$  de la table.

Dans ces tables, la colonne <ENT><être> permet de coder le verbe être mais également pas, plus, jamais, point, ni, donc, bien, toujours, que ou une combinaison de ceux-ci. Cela permet aussi d'indiquer dans de rares cas une variante du verbe être, telles que va être, Lui être, est-ce, soit, avoir été ou es-tu, dont voici quelques exemples :

```
\langle E \rangle ça va être \langle E \rangle la fête
```

<E> il Lui est d'<E> avis que P

 $\langle E \rangle$  qu'est-ce qu'il y a?

le ciel soit loué!

la journée a été longue

Il faut donc traiter ces expressions comme étant des expressions totalement figés, y compris au niveau verbe. A part pour ces cas-là, la colonne <ENT><être> doit être toujours à l'infinitif pour indiquer que le verbe peut être conjugué à tous les modes et à tous les temps. N'ayant aucune information sur la personne, il sera conjugué également

<sup>21.</sup> Pour plus de lisibilité, les ellisions des déterminants ont été systématiquement faites pour chaque entrée et ne sont indiquées entre parenthèses que dans le cas où la préposition et le déterminant ne forme plus qu'un seul mot, comme c'est le cas ici, pour rendre compte des deux mots codés dans la table.

<sup>22.</sup> Ppv ne figure pas non plus dans cette table parmi les constituants de la construction de base puisque cela ne concerne qu'une entrée. Aucun <E> ne correspond donc à la colonne <ENT>Ppv.

à toutes les personnes.

De plus, nous avons dupliqué cette colonne pour garder la conjugaison originale telle qu'elle est dans les exemples (colonne Exemple) : la colonne <ENT>est n'est donc là qu'à titre informatif. Dans de rares cas, le verbe est dans un autre temps que le présent :

il était une fois un N qui V W

ça sera un café pour Max!

il fut un temps où P

Ceci était codé à l'origine dans <ENT><être>, nous avons préféré laissé l'infinitif, car dans certains cas tous les temps sont possibles. Par exemple, c'était donc ça! ou ce sera pour une autre fois (les phrases c'est pour une autre fois ou ce serait pour une autre fois sont acceptables). Au présent, nous avons conjugué le verbe être comme suit :

- sont lorsque <ENT>Det0 = les, <ENT>Det0 = Det, suivi d'un nom au pluriel ou <ENT>C0 = ils;
- est lorsque <ENT>Det0 = le, <ENT>Det0 = la, <ENT>Det0 = Det, suivi d'un nom au singulier, <ENT>C0 = il ou <ENT>C0 = on;
- suis, es, sommes ou êtes lorsque <ENT>C0 = je, <ENT>C0 = tu, <ENT>C0 = nous ou <ENT>C0 = vous, ce qui était déjà fait pour certaines entrées.

La construction de base de chaque table dépend donc de la construction prévue au départ par M. Gross, en incluant les intitulés des différentes colonnes qui codent les mots de l'entrée figée. Les constructions de base de chaque table sont détaillées dans la section 6.6. Quelques tables méritent un commentaire, car elles ont plus d'une propriété définitoire :

- les tables C1D, C1DPN, C1I et C1IPN contiennent la nature du déterminant figé, qui peut être soit défini (Det1 =: déf) pour les tables C1D (abandonner la compétition) et C1DPN (abaisser les bras devant), soit indéfini (Det1 =: indéf) pour les tables C1I (allumer une mèche) et C1IPN (accorder une large confiance à);
- les tables C5 (bouillonner dans le ciboulot) et C5C1 (aller contre l'évidence) sont des tables à complétives sujet (N0 =: Qu P);
- la table E1HC (*être une andouille*) a un sujet humain (N0 =: Nhum);
- la table EPAC (être d'un mauvais acabit) a pour construction de base
   N0 être Prép1 Det1 Adj1 C1, l'adjectif étant toujours placé avant le nom. Comme il s'agit de l'ordre inhabituel par rapport aux autres tables, la propriété Adj1 permut obl a été ajoutée pour clarifier l'ordre des mots de l'expression figée;
- la table CAN (abattre le moral) avait à l'origine la construction de base N0 V Det1 C1 (à+de) Nc, que nous avons scindée en deux : N0 V Det1 C1 à Nc comme construction de base et N0 V Det1 C1 de Nc comme deuxième construction définitoire, la table CDN ayant N0 V Det1 C1 de Nc comme construction de base (allonger le pas);
- la table EC0 (c'être de l'algèbre <E> <E> <E> pour) avait à l'origine la construction de base Ce être Prép1 Det1 C1 Prép2 Det2 C2 Prép3 N3 alors que le troisième complément n'est pas toujours possible (ce n'être pas le tout <E> <E> <E>, la valeur de la colonne <ENT>Prép3 ne figurant pas dans cette entrée), nous l'avons donc renommée Ce être Prép1 Det1 C1 Prép2 Det2 C2. Ensuite, dans la table,

nous avons ajouté la colonne Ce être Prép1 Det1 C1 Prép2 Det2 C2 Prép3 N3 avec la valeur + lorsqu'au moins l'une des cinq colonnes suivantes vaut + : N3 =: Nhum, N3 =: N-hum, N3 =: ce Qu Pind, N3 =: ce Qu Psubj et N3 =: (de) V-inf W. De plus, la colonne <ENT>Prép3 est mise à - (et non <E>) lorsque cette nouvelle colonne est codée - pour distinguer les cas où la préposition vaut réellement <E> (c'être le cas de <E> dire <E>) des cas où le complément n'existe pas ;

- la table CV (sentir de quel côté venir le vent) a pour construction de base N0 V Prép1 (Det1 C1+N1) V2 Prépv (Detv Cv+Nv) mais les colonnes Prépv et Detv sont fusionnées en une seule colonne intitulée <ENT>PrépDetv (correspondant à le dans l'exemple précédent et à par dans ne demander qu'à se laisser convaincre par), mais cela ne pose pas de problème pour récupérer l'entrée complète.

## 6.4.2 Classes d'expressions figées de J. Giry-Schneider

Les tables FC à FCPNN de J. Giry-Schneider sont 9 classes d'expressions figées suivant les mêmes principes que les tables de noms prédicatifs à verbe support *faire* (FN à FNPNN) de J. Giry-Schneider. La différence est que leur déterminant est figé, comme cela est décrit dans Giry-Schneider (1987) (p. 153). Leur construction de base est donc établie de la même manière que pour les classes d'expressions figées précédentes, avec la structure complète dans la phrase.

L'ensemble des tables dont le nom commence par FC ont pour construction de base :

- table FC (faire l'affaire) : N0 faire Det1 C1;
- table FCA (faire l'enfant gâté) : N0 faire Det1 C1 Adj1;
- table FCN (faire la part des choses) : N0 faire Det1 C1 Prépc Detc Cc.

L'ensemble des tables dont le nom commence par FCPN ont pour construction de base :

- table FCPN (faire la croix sur) : N0 faire Det1 C1 Prép2 N2;
- table FCPNA (faire table rase de): N0 faire Det1 C1 Adj1 Prép2 N2;
- table FCPNN (faire le pied de grue Loc) : N0 faire Det1 C1 Prépc Detc Cc Prép2 N2.

L'ensemble des tables dont le nom commence par FCAN ont pour construction de base :

- table FCAN (faire la gueule à) : N0 faire Det1 C1 à N2;
- table FCANA (faire la courte échelle) : N0 faire Det1 C1 Adj1 à N2;
- table FCANN (faire la chasse à l'homme) : N0 faire Det1 C1 Prépc Detc Cc à N2.

#### 6.4.3 Classe de verbes 311

La table 31I (sujet II) est décrite dans Boons et al. (1976b) (p. 263), elle est à l'origine une classe de verbes avec comme construction de base II V (Il pleut). Nous la considérons actuellement comme une classe d'expressions figées, car le sujet est figé et noté C0, ce qui est également le cas d'autres classes, comme nous l'avons mentionné précédemment. De plus, des entrées ont été ajoutées n'acceptant pas le sujet il mais ça, comme dans ça dégringole. Par ailleurs, toutes les entrées acceptant le sujet il, acceptent également le sujet ça (ça pleut). Nous avons donc noté la construction de base C0 V avec C0 =: ça (et

non N0 =: il+ça, ainsi que cela est noté dans Leclère (1990)), ceci étant également justifié par le fait que la colonne C0 =: il est codée dans la table. Par ailleurs, une construction avec un sujet libre étant également possible pour certains verbes, la colonne  $N0 \lor W$  (Les tomates pleuvent (E+sur la scène)) est également codée dans la table.

### 6.4.4 Constructions en être Prép X

Les tables Z à ZS de L. Danlos décrites dans Danlos (1980) (p. 117) sont au nombre de 8, mais seulement 5 ont été numérisées et corrigées manuellement : Z5D, Z5P, Z1, ZS et  $\mathbb{Z}P^{23}$ . Seules les entrées de ces 5 tables font partie du lexique LGLex.

De la même manière que pour certaines tables de M. Gross (EPAC à EPDETC, cf. 6.4.1), plutôt que de les considérer comme des expressions figées verbales, on peut les considérer comme des expressions figées adjectivales (voire adverbiales) avec le verbe support être. Le point important est de savoir quels sont le ou les verbes supports possibles, y compris en fonction de l'aspect. Par exemple, pour l'entrée (être+partir) à la retraite, à la retraite est un adjectif (Les gens à la retraite sont pauvres), mais cela n'est pas peut-être pas le cas pour toutes les entrées. C'est pourquoi pour simplifier la classification, nous les avons laissées dans la catégorie des expressions figées. Il faudrait également comparer toutes les entrées avec celles de M. Gross pour voir s'il y a des doublons.

Les propriétés définitoires ont été définies comme suit (la première étant la construction de base) :

- table Z5D (être à la charge de) : N0 être Prép1 Det1 C1 de N2, il être Prép1 Det1 C1 de N2 Qu P et N0 =: Qu P. La colonne <ENT>Prép2 ne figurant pas dans cette table, elle a été ajoutée, même si valeur vaut de pour toutes les entrées. En effet, cela permet d'avoir l'entrée complète (plus lisible), à savoir avec la préposition figée. Ces modifications ont également été réalisées pour les tables Z1 et ZD;
- table Z5P (être de la première urgence pour) : N0 être Prép1 Det1 C1 (E+Prép2 N2), il être Prép1 Det1 C1 (E+Prép2 N2) Qu P, Prép2 # de et N0 =: Qu P (Z5D et Z5P sont les deux uniques tables à accepter cette propriété). Le deuxième complément n'étant pas toujours possible (être dans l'ombre d'un doute, la valeur de la colonne <ENT>Prép2 ne figurant pas dans cette entrée), les deux premières constructions ont été renommées en N0 être Prép1 Det1 C1 et il être Prép1 Det1 C1 Qu P. Ensuite, dans la table, les deux constructions N0 être Prép1 Det1 C1 Prép2 N2 et il être Prép1 Det1 C1 Prép2 N2 Qu P ont été ajoutées avec la valeur lorsque l'une des 2 colonnes N2 =: Nhum et N2 =: N-hum vaut +. La colonne <ENT>Prép2 contient la préposition codée lexicalement dans ces cas-là également, dans les autres cas, elle vaut —. De plus, la colonne N0 être Prép1 Det1 C1 a été supprimée de la table, puisqu'elle codait la possible omission du N2 et était codée + pour toutes les entrées sauf une, ce qui ne semble pas pertinent;

<sup>23.</sup> Nous avons réalisé ce travail en collaboration avec Jean-Pierre Heymann en 2009.

- table Z1 (être à un poil de): N0 être Prép1 Det1 C1 de V0-inf W et N2 =: Qu P (unique table à accepter cette propriété);
- table ZS (être au (=à le) téléphone avec) : N0 être Prép1 Det1 C1 avec N2 que nous avons renommée N0 être Prép1 Det1 C1 Prép2 N2, la colonne <ENT>Prép2 codant lexicalement la préposition, et N0 et N2 être Prép1 Det1 C1;
- table ZD (être de l'acabit de) : N0 être Prép1 Det1 C1 de N2;
- table ZP ( $\hat{e}tre\ aux\ (=\hat{a}\ les)\ petits\ soins\ avec$ ) : N0 être Prép1 Det1 C1 Prép2 N2 et Prép2 # de ;
- table ZM (être à l'agonie) : N0 être Prép1 Det1 C1 et Vop = mettre (propriété qui n'est pas acceptée par la table suivante);
- table Z ( $\hat{e}tre\ \hat{a}\ l'abandon$ ) : N0 être Prép1 Det1 C1.

Les tables de L. Danlos décrites dans Danlos (1980) ont été reprises par L. Danlos et existent dans une version plus complète (avec plus d'entrées), décrite dans Danlos (1988). Leur nombre est de 24 classes, la plupart ayant été numérisées  $^{24}$ , sans avoir encore été corrigées afin de pouvoir être intégrées (leurs entrées ne font donc pas partie du lexique LGLex). Malheureusement, 5 d'entre elles n'ont pas été retrouvées. C'est la raison pour laquelle nous ne faisons pas figurer ces tables dans la section 6.6, nous les détaillons uniquement ici. Nous indiquons pour chaque table de Danlos (1980), les tables en lesquelles elles ont été divisées Danlos (1988) (p. 35) :

- table Z5D: tables Z5CDN (être du (=de le) goût de) et ZT5CDN (être dans les cordes de);
- table Z5P : tables Z5CPN ( $\hat{e}tre\ sans\ < E>\ espoir\ pour$ ) et ZT5CPN ( $\hat{e}tre\ \hat{a}\ < E>\ propos$ ) (qui n'a pas été retrouvée mais qui doit comporter un petit nombre d'entrées que l'on peut retrouver en comparant les tables Z5P et Z5CPN);
- table Z1: tables Z1C (être dans l'impossibilité de) et ZT1C (être à la veille de) (qui n'a pas été retrouvée et qui ne figure même pas dans l'index, mais on peut retrouver facilement les entrées);
- table ZS: tables ZCSY (être en <E> froid avec) et ZTCSY (être en <E> conflit avec);
- table ZP: tables ZCPN ( $\hat{e}tre\ en\ route\ pour$ ) et ZTCPN ( $\hat{e}tre\ en\ < E > extase\ devant$ )
- table ZD: tables ZCDN (être à la merci de) et ZTCDN (être sous la botte de) (on peut donc remplacer ZD par ces tables, sans la numériser);
- table ZM: tables ZMC (être aux (=à les) abois), ZMAC (être de <E> bon poil),
   ZMCA (être à l'heure juste) et ZMCDC (être aux (=à les) arrêts de rigueur) (on peut donc remplacer ZM par ces tables, sans la numériser);
- table Z : tables ZC (être de <E> parole), ZAC (être de <E> bas étage), ZCA (être à <E> ciel ouvert), ZCDC (être à la noix de coco) et ZTCDC (être à l'article de la mort), tables que l'on a retrouvées mais aussi ZTC (être en <E> arrêt), ZTAC (être à la dernière extrémité), ZTCA (être en <E> terrain acquis), qui n'ont pas été retrouvées (on ne peut donc pas remplacer Z par ces tables, il faut donc la numériser). Ceci nous empêche de remplacer toutes les tables de Danlos (1980) par

<sup>24.</sup> Nous avons réalisé ce travail en collaboration avec Jean-Pierre Heymann en 2010.

celles de Danlos (1988).

Ces tables se différencient par le fait que toutes les tables dont le nom commence par ZT ont des variantes aspectuelles utilisant des verbes de mouvement, ce qui implique que le verbe *être* admet des variantes aspectuelles des verbes de mouvement (Vmt) comme *entrer*, *arriver*, *tomber*, ou que le verbe *être* admet des opérateurs causatifs de mouvement (Vcmt) comme *conduire*, *envoyer*, *pousser*, ce qui est noté par les deux constructions suivantes qui sont définitoires de ces tables :

N0 Vmt Prép X W N Vcmt N0 Prép X W

### 6.5 Les classes des adverbes

Les classes des adverbes (cf. Tab. 5.1(d)) sont au nombre de 32. Nous commençons par étudier la différences des propriétés présentes dans les différentes tables d'adverbes (6.5.1), puis nous verrons en détail les différentes classes d'adverbes en -ment (6.5.2) et d'adverbes (semi-)figés (6.5.2), tout en précisant pour chacune leur construction de base. L'adverbe, qu'il soit simple ou composé, est noté Adv dans les constructions.

## 6.5.1 Propriétés distinctes

On dispose de deux ressources d'adverbes qui ne traitent pas le même ensemble de propriétés, comme nous l'avons évoqué dans Tolone et al. (2010). Il s'agit, d'une part, des adverbes monolexicaux en -ment de Moliner (1984); Molinier et Levrier (2000), qui sont dérivés essentiellement des adjectifs et, d'autre part, des adverbes polylexicaux ou complexes (semi-)figés de Gross (1986a, 1990). Ces deux ressources suivent, comme toutes les tables du Lexique-Grammaire, les mêmes principes de représentation : prise en compte de la phrase complète, utilisation d'intitulés compacts et lisibles, etc. C'est pourquoi nous avons jugé intéressant de les combiner, créant ainsi une seule table des classes correspondant à l'ensemble des classes d'adverbes.

Les classes d'adverbes en *-ment* suivent la classification sémantique de la grammaire traditionnelle (temps, manière, etc.) et les propriétés décrivent principalement la place de l'adverbe dans la phrase.

Pour ce qui est des adverbes (semi-)figés, les propriétés décrivent une structure de phrase simple, le plus souvent à prédicat verbal intransitif dont le sujet humain (N0 =: N-hum) ou non humain (N0 =: N-hum), est décrit et codé dans les deux premières colonnes des tables. La représentation de la combinatoire de l'adverbe avec une structure explicite de phrase élémentaire permet de rendre compte des relations de *portée* de l'adverbe sur un élément de la phrase :

La réunion devra avoir lieu **au plus tard** le 15 juin (table PAC)

Dans l'exemple ci-dessus, l'adverbe au plus tard porte sur l'adverbe de date le 15 juin. De manière générale, cet adverbe modifie obligatoirement un complément de temps. Des contraintes de temps ou d'aspect s'observent aussi comme dans l'exemple :

Les tablettes remplaceront les PC dans un avenir proche (table PCA)

\* Les tablettes (ont remplacé + remplacent + remplaçaient) les PC dans un avenir proche

Les propriétés de compléments libres (par exemple, sous réserve de N), qui sont importantes pour l'analyse syntaxique, sont codées dans les classes d'adverbes (semi-)figés mais ne figurent pas dans les adverbes en -ment (par exemple, contrairement à N).

Malgré leurs différences, les deux types d'adverbes sont complémentaires et sont souvent liés par des relations de paraphrase (productives et régulières) permettant de former des couples de synonymes, comme en témoignent les exemples suivants :

```
pratiquement (table ADVPS) = en pratique (table PC)
franchement (table ADVPS) = à franchement parler (table PV)
sincèrement (table ADVMS) = de (manière+façon) sincère (table PCA)
politiquement (table ADVMP) = d'un point de vue politique (table PCA)
malheureusement (table ADVPAE) = par malheur (table PC)
```

Notons qu'il existe au moins deux emplois adverbiaux correspondant à la forme franchement : d'une part, adverbe de manière orienté vers le sujet appartenant à la table ADVMS, et qui peut être paraphrasé par de manière franche (PCA) et avec franchise (PC); et, d'autre part, adverbe de phrase disjonctif de style (ou d'énonciation) appartenant à la classe ADVPS et admettant les paraphrases à franchement parler (PV) et en toute franchise (PDETC). De manière similaire, sincèrement a un premier emploi en tant qu'adverbe de manière orienté vers le sujet (paraphrasable par de (manière+façon) sincère et avec sincérité) et un deuxième emploi en tant qu'adverbe de phrase disjonctif de style (ou d'énonciation) (paraphrasable par en toute sincérité). Enfin, pratiquement peut être adverbe de manière verbal (ADVMV) ou adverbe de manière focalisateur (ADVMF) ou encore, adverbe de phrase disjonctif de style (ou d'énonciation), paraphrasable par en pratique (PC).

Toutefois, cette information significative n'apparaît pas dans les tables du Lexique-Grammaire à cause de la dispersion des adverbes concernés dans les différentes classes. Comme le signale Gross (1990) (p. 56), «seul un système de renvois explicites permettrait ces regroupements sémantiques des adverbes». Il faudrait donc faire référence à l'identifiant de l'adverbe dans les tables d'adverbes simples pour chaque adverbe (semi-)figé concerné et vice-versa.

L'objectif de notre travail, entre autres, est de fournir une description complète à la fois des adverbes en *-ment* et des adverbes (semi-)figés, permettant ainsi d'établir un continuum entre les deux types d'adverbes. C'est pourquoi, à la différence des autres catégories, l'homogénéisation des tables a permis définir la représentation des adverbes <sup>25</sup>.

Les principales modifications effectuées concernent : la définition et le codage des constructions de base pour toutes les classes, l'ajout des propriétés lexicales mettant en jeu les noms et les adjectifs qui participent aux procédures transformationnelles et

<sup>25.</sup> Nous avons réalisé ce travail en collaboration avec Stavroula Voyatzi en 2010-2011 (Tolone *et al.*, 2010). Notons que le même travail combinant les tables de verbes simples et les expressions figées verbales pourrait être envisagé, de même qu'avec les adjectifs quand les tables seront terminées, cependant toutes les raisons énumérées pour les adverbes ne sont pas forcément valables pour les autres catégories.

paraphrastiques, et l'ajout des propriétés de paraphrase <sup>26</sup>.

### 6.5.2 Adverbes en -ment

Les classes d'adverbes monolexicaux en -ment de C. Molinier sont divisées en 9 grandes catégories, avec un découpage plus fin pour certaines catégories, ce qui aboutit à un total de 16 classes, comme cela a été présenté dans Sagot et Fort (2007). Une première partition est établie entre adverbes de phrase ou adverbes de statut périphérique, et adverbes intégrés à la proposition, c'est-à-dire rattachés au verbe ou à tout autre constituant de la proposition.

Les adverbes de phrase sont regroupés dans six classes, dont le nom commence par ADVP. On peut distinguer trois grandes classes d'adverbes de phrase :

- les conjonctifs (table ADVPC) nécessitent un contexte gauche auquel ils renvoient (Hâte-toi, autrement tu seras en retard);
- les disjonctifs regroupent les autres adverbes de phrase. Parmi ceux-ci, les disjonctifs de style ou d'énonciation (table ADVPS) qualifient la manière de présenter les choses par le locuteur (Honnêtement, c'est un fiasco);
- les autres adverbes disjonctifs sont les disjonctifs d'attitude ou d'énoncé, qui se subdivisent en quatre sous-classes : les disjonctifs d'attitude évaluatifs (table ADV-PAE : curieusement), les disjonctifs d'attitude d'habitude (table ADVPAH : habituellement), les disjonctifs d'attitude modaux (table ADVPAM : certainement) et les disjonctifs d'attitude orientés vers le sujet (table ADVPAS : sottement).

Les adverbes intégrés à la proposition sont organisés en dix classes, dont le nom commence par ADVM. On peut distinguer six grandes classes d'adverbes intégrés à la proposition :

- les adverbes de manière orientés vers le sujet (table ADVMS : Max regarde anxieusement l'horizon);
- les adverbes de manière verbaux (table ADVMS : Max regarde fixement l'horizon);
- les adverbes de manière quantifieurs (une classe découpée en trois tables dont le nom commence par ADVMQ : Max aime énormément ce tableau). Les adverbes indiquent la complétude (table ADVMQC : partiellement) ou l'extension qualitative (table ADVMSQE : fondamentalement), les autres quantifieurs étant intensifs (table ADVMQI : énormément);
- les adverbes de point de vue (table ADVMP : **Légalement**, je suis responsable);
- les adverbes de temps (une classe découpée en trois tables dont le nom commence par ADVMT : Je suis venue ici dernièrement). On distingue dans cette classe les adverbes de durée (table ADVMTD : définitivement), les adverbes de fréquence (table ADVMTF : constamment) et les autres adverbes de temps (table ADVMTQ : dernièrement).
- les adverbes focalisateurs (ADVMF : Je lis principalement des romans).

<sup>26.</sup> Signalons que le codage des paraphrases (notamment, le codage des propriétés lexicales associées) n'étant pas terminé, uniquement certaines propriétés de paraphrases apparaissent dans la version 3.3, les autres seront incluses dans la suivante (Tolone et Voyatzi, 2011).

Les classes des adverbes monolexicaux en *-ment* de C. Molinier sont syntaxiquement homogènes, c'est-à-dire que chaque classe correspond à une seule classe syntaxico-sémantique des adverbes. Il a donc été facile d'attribuer les constructions définitoires à chaque classe. Les deux constructions Adv, N0 V W et Adv, N0 ne V pas W étaient initialement codées dans les tables des adverbes de manière et des adverbes de phrase. Nous avons supprimé la colonne lorsque la valeur était constante pour toutes les entrées d'une table, afin de rendre compte des constructions définitoires.

Les classes des adverbes de manière (dont le nom commence par ADVM) ont pour construction de base N0 V Adv W, ce qui signifie que l'adverbe peut être placé après le verbe :

Ce livre est en vente exclusivement sur ce site (table ADVMF)

\*Exclusivement, ce livre est en vente sur ce site

De plus, les tables ADVMP, ADVMS et ADVMTF admettent Adv, N0 V W (l'adverbe peut aussi être placé en tête d'une phrase affirmative) :

Ce livre est en vente régulièrement sur ce site (table ADVMTF)

Réqulièrement, ce livre est en vente sur ce site

\*Régulièrement, ce livre n'est pas en vente sur ce site

La table ADVMP admet également Adv, N0 ne V pas W (l'adverbe peut aussi être placé en tête d'une phrase négative) :

Ce concert est musicalement une réussite

Musicalement, ce concert est une réussite

Musicalement, ce concert n'est pas une réussite

Les classes des adverbes de phrases (dont le nom commence par ADVP) ont pour constructions définitoires Adv, N0 V W et Adv, N0 ne V pas W (l'adverbe peut être placé en tête de phrase affirmative ou négative) :

Cinquièmement, Sunrider utilise des sous-produits animaux (table ADVPC)

Cinquièmement, Sunrider n'utilise aucun sous-produit animal

\*Sunrider n'utilise cinquièmement aucun sous-produit animal

De plus, la table ADVPC admet la construction définitoire P1 Adv P2 (l'adverbe peut relier deux phrases).

# 6.5.3 Adverbes (semi-)figés

Les adverbes (semi-)figés de M. Gross sont polylexicaux ou complexes, c'est-à-dire composés de plusieurs mots. Ils sont regroupés dans des classes en fonction de leur structure morpho-syntaxique, de la même manière que les expressions figées. On a donc diverses colonnes codant la forme des adverbes et leurs variantes éventuelles (effacement de l'adjectif figé, etc.). Ces propriétés de structure n'apparaissent pas dans les tables d'adverbes en *-ment* puisqu'ils ne sont composés que d'un seul mot.

Les classes des adverbes (semi-)figés de M. Gross suivent le découpage suivant :

- table PAC: à modifieur adjectival anteposé;
- table PADV : monolexical figé;
- table PC: sans déterminant et sans modifieur;
- table PCA: à modifieur adjectival postposé;

```
table PCDC: à complément de nom figé de type de C;
table PCDN: à complément de nom libre de type de N;
table PCONJ: conjonction de deux ou plusieurs adverbes figés;
table PCPC: à complément de nom figé de type Prép C;
table PCPN: à complément de nom libre de type Prép N;
table PDETC: avec déterminant et sans modifieur;
table PECO: comparatif rattaché à un adjectif;
table PF: phrastique à sujet explicite;
table PJC: conjonctif figé;
table PPCO: comparatif de structure prépositionnelle;
table PV: phrastique à sujet non explicite;
table PVCO: comparatif rattaché à un verbe.
```

Ce découpage ne suit donc pas celui des classes des adverbes en -ment. Par exemple, dans la table PAC sont codés à la fois des adverbes conjonctifs (dans un premier temps, en dernier lieu), des adverbes de phrase (à Possô humble avis, en toute première approximation), des adverbes de temps (en plein automne, depuis cent sept ans), des adverbes de manière verbaux (tout bêtement, n'importe comment), etc. C'est pourquoi il n'est pas possible d'établir une construction de base pour une table donnée. Il faudrait en effet coder les constructions pour chaque entrée adverbiale, ce qui serait long à réaliser. Nous avons donc décidé de considérer qu'un adverbe (semi-)figé pouvait se placer n'importe où dans la phrase, même s'il s'agit d'une généralisation abusive. Ainsi, tous les adverbes de la table PC (cf. Fig. 3.6) n'admettent pas Adv, NO V W, par exemple :

Luc fait du piano à volonté

\*À volonté, Luc fait du piano

Les tables des adverbes (semi-)figés, au nombre de 16 (dont le nom commence par P), admettent donc les trois constructions définitoires suivantes :

N0 V Adv W Adv, N0 V W

Adv, N0 ne V pas W

De plus, nous avons défini pour chaque classe la construction morpho-syntaxique interne de l'adverbe, appelée *structure de base*. Elle remplace la construction de base n'existant pas ici puisque cette structure de base n'entre pas dans une seule construction, comme c'est le cas pour les expressions figées. En revanche, de même qu'une construction de base, elle peut avoir des variantes, par effacement ou ajout de compléments.

Par exemple, pour la table PCPC, la structure de base est Prép1 Det1 C1 Prép2 Det2 C2, comme c'est le cas pour l'entrée [changer] du (=de le) jour au (=à le) lendemain  $^{27}$ . La colonne Prép1 Det1 C1 est codée dans la table et représente l'effacement du deuxième complément. Cette propriété n'est pas acceptée pour l'entrée précédente, en revanche, elle l'est pour l'entrée [n'agir] pour <E> rien au (=à le) monde, et permet de reconnaître la variante [n'agir] pour <E> rien.

<sup>27.</sup> Le verbe entre crochets est codé dans la colonne **Prédicat type**, il ne fait pas partie de l'entrée, mais est donné à titre indicatif.

De même, que pour la construction de base des expressions figées, chaque structure de base dépend donc des intitulés des différentes colonnes qui codent les mots de l'entrée (semi-)figée. Les détails de chaque structure de base pour chaque table sont dans la section 6.6. Notons que la table PV n'a pas de structure de base bien définie, mais le choix entre les deux structures de base Prép V Prépv Detv Cv et Prép Prépv Detv Cv V, qui sont des colonnes codées dans la table. La structure de base des adverbes simples en -ment a simplement été notée Adv.

Nous devons noter la présence d'adverbes libres avec un prédicat d'une autre catégorie pour les trois tables suivantes : PECO contenant des adjectifs prédicatifs composés et PPCO et PVCO contenant des expressions figées verbales. En effet, la table PECO admet également comme construction N0 être Adj, où l'adjectif a une structure en Adj comme Det C (Max est doux comme un ange) 28. Dans cet exemple, doux comme un ange est l'adjectif composé, alors que l'adverbe libre a uniquement la structure comme Det C (ici, comme un ange). La table PPCO a comme construction N0 V comme Prép Det C (marcher comme sur des roulettes) et la table PVCO a comme construction N0 V comme Det C (partir comme une fusée) 29. Dans ces exemples, l'adverbe libre est comme sur des roulettes et comme une fusée, et possède uniquement la structure comme Prép Det C pour la table PPCO, ou comme Det C pour la table PVCO.

Actuellement, ces adverbes font partie du lexique des adverbes, c'est pourquoi nous appelons les entrées des adjectifs prédicatifs et expressions figées correspondantes des entrées supplémentaires, parallèlement aux autres entrées supplémentaires déjà mentionnées (cf. 6.3.1 et 6.3.3). Lorsque les tables des adjectifs prédicatifs et le lexique qui en découle sera créé, on pourra inclure ces entrées comme des entrées principales dans le lexique des adjectifs prédicatifs ou celui des expressions figées, et supprimer ainsi les entrées adverbiales.

### 6.6 Recensement

Nous donnons d'abord le nombre d'entrées dans chaque table, puis nous récapitulons l'ensemble des propriétés définitoires détaillées tout au long de ce chapitre, avant de conclure.

## 6.6.1 Nombre d'entrées de chaque table

Voici le bilan du nombre d'entrées par catégorie (en comptant les expressions figées à part) :

- 13 867 entrées verbales, dont 5 738 verbes distributionnels simples distincts (réparties dans 67 tables);
- 12 696 entrées nominales, dont 8 531 noms prédicatifs simples et composés distincts (réparties dans 78 tables);

<sup>28.</sup> L'adjectif doux est contenu dans la colonne < OPT>Adj figé.

<sup>29.</sup> Le verbe marcher (respectivement, partir) est contenu dans la colonne <OPT>V figé.

- 39 628 entrées figées, dont 38 658 expressions figées distinctes incluant principalement les catégories verbales et adjectivales (réparties dans 69 tables);
- 10 488 entrées adverbiales, dont 9 326 adverbes simples et (semi-)figées distincts (réparties dans 32 tables).

Pour plus de détails, le nombre d'entrées par table figure dans les Tab. 6.1 à Tab. 6.7. Les propriétés codées pour toutes ces entrées sont regroupées dans chacune des tables des classes de la catégorie concernée :

- la table des classes des verbes regroupe 551 propriétés;
- celle des noms prédicatifs 496 propriétés;
- celle des expressions figées 276 propriétés;
- celle des adverbes 159 propriétés.

À cela, on peut ajouter les quelques entrées supplémentaires déjà mentionnées :

- les tables DR1, DRC, FR1, FS1, IS1, ES et AD de G. Gross (cf. 6.3.3) et les tables F1A à F91 (cf. 6.3.2) de J. Giry-Schneider qui codent également des verbes distributionnels simples : elles comportent 3 334 entrées pour 2 377 lemmes distincts (dans 24 tables au total). Remarquons, comme cela a été explicité dans 6.3.2, que les classes de J. Giry-Schneider ne concernent pas de nouveaux verbes, puisque les classes faisant référence aux verbes déjà existants sont indiquées dans la table. De plus, les classes de G. Gross contiennent aussi des verbes déjà existants, mais il est nécessaire les étudier au cas par cas;
- les tables AN01 à AN06 et ANSY de A. Meunier (cf. 6.3.1), ainsi que la classe ES de G. Gross (cf. 6.3.3) qui codent également des adjectifs prédicatifs simples : elles comportent 1 408 entrées pour 1 287 lemmes distincts (dans 8 tables au total);
- les 2 tables d'adverbes qui codent également des expressions figées verbales (PPCO et PVCO) (cf. 6.5.3) : elles comportent 388 entrées pour 385 lemmes distincts;
- la table d'adverbes PECO (cf. 6.5.3) qui code également des adjectifs prédicatifs composés : elle comporte 304 entrées pour 300 lemmes distincts.

## 6.6.2 Propriétés définitoires de chaque table

Les Tab. 6.1 à Tab. 6.7 recensent l'ensemble des propriétés définitoires vraies pour toutes les entrées d'une table, qui sont mentionnées dans ce chapitre, incluant les constructions de base ou les structures de base pour les adverbes. De plus, le nombre d'entrées par table figure dans la deuxième colonne. La notation V<sub>-</sub> indique qu'il s'agit de classes de verbes, N<sub>-</sub> de noms, C<sub>-</sub> d'expressions figées et P<sub>-</sub> d'adverbes. Nous avons également laissé la notation en minuscules pour les classes de noms, d'expressions figées et d'adverbes, pour des raisons de conformité avec le nom réel des fichiers. Rappelons que pour les verbes, la formule définitoire complète pour chaque table, c'est-à-dire incluant aussi bien les propriétés définitoires vraies que fausses pour l'ensemble d'une table, ainsi que les disjonctions de propriétés codées dans les tables, est donnée dans l'annexe F. Nous avons noté entre accolades les propriétés non présentes dans cette annexe car elles ne participent pas à la définition de la table, mais que nous avons mentionnées dans ce chapitre comme étant constantes +.

| Tables                               | Entr. | Construction de base                       | Autres propriétés définitoires                 |  |
|--------------------------------------|-------|--|--|--|
| V_1                                  | 117   | N0 V Prép V0-inf W                         |  |  |
| V_2                                  | 195   | N0 V Loc N1 V0-inf W                       | {N0 V Loc N1}                                  |  |
| V_2T                                 | 24    | NO V N1 V0-inf W                           | {N0 V N1}                                      |  |
| V_3                                  | 54    | N0 V N1 Loc N2 V1-inf W                    | {N0 V N1 V1-inf W; N0 V N1 Loc N2}             |  |
| V_4                                  | 695   | N0 V N1                                    | N0 =: Qu P; N1 =: Nhum {N0 =: Nnr}             |  |
| V_5                                  | 161   | NO V Prép N1                               | N0 =: Qu P; [extrap]                           |  |
| V_6                                  | 518   | NO V N1                                    | , , [ 1]                                       |  |
| $V_{-7}$                             | 161   | N0 V à N1                                  |  |  |
| V_8                                  | 193   | N0 V de N1                                 |  |  |
| V_9                                  | 432   | N0 V N1 à N2                               | N2 =: Nhum                                     |  |
| V_10                                 | 225   | N0 V N1 Prép N2                            |  |  |
| V_11                                 | 226   | N0 V N1 à N2                               |  |  |
| V_12                                 | 62    | N0 V N1                                    | N1 =: Qu Psubj;                                |  |
| V_13                                 | 155   | N0 V N1 de N2                              | Qu Psubj =: Qu Ni Vsubj W = (Ni) (de Vi-inf W) |  |
| V <sub>-13</sub><br>V <sub>-14</sub> | 21    | NO V N1 de N2<br>NO V à N1 Prép N2         |  |  |
| V_14<br>V_15                         | 82    | NO V de N1 Prép N2                         |  |  |
| V_16                                 | 78    | NO V de N1 Prep N2<br>NO V Prép N1 Prép N2 |  |  |
| V_10<br>V_18                         | 26    | NO V Prép N1 Prép N2 Prép N3               |  |  |
| V_18<br>V_31H                        | 633   | NO V Prep N1 Prep N2 Prep N3               | N0 =: Nhum                                     |  |
| V_31R                                | 386   | NO V                                       | NO =: N-hum                                    |  |
| V_31R<br>V_32A                       | 162   | NO V N1                                    | N1 apparition; [passif par]                    |  |
| V_32A<br>V_32D                       | 8     | NO V N1                                    | N1 disparition; [passif par]                   |  |
| V_32D<br>V_32C                       | 373   | NO V N1                                    | $N1 =: N-hum; [passif par] {N1 =: Nconc}$      |  |
| V_32CL                               | 121   | NO V N1                                    | N1 =: Npc; N0 V N1 Loc N1pc W; [passif par]    |  |
| V_32CV<br>V_32CV                     | 114   | NO V N1 en N2                              | N2 être V-n {N0 V N1; N2 apparition}           |  |
| V_32H                                | 730   | NO V N1                                    | N1 =: Nhum                                     |  |
| V_32NM                               | 140   | NO V N1                                    | TVI —. TVIIIIII                                |  |
| V_32PL                               | 139   | NO V N1                                    | N1 =: Npl obl; [passif par]                    |  |
| V_32R1                               | 98    | NO V N1                                    | N0  V  (N1  de  N1c) = N0  V  (N1c) (Prép N1); |  |
| V =02101                             |       | 110 1111                                   | N1 =: Nabs; [passif par]                       |  |
| V_32R2                               | 472   | N0 V N1                                    | N1 =: Nabs; [passif par]                       |  |
| V_32R3                               | 1 027 | NO V N1                                    | [passif par]                                   |  |
| V_32RA                               | 471   | NO V N1                                    | [passif par] {N0 =: Nnr}                       |  |
| V_33                                 | 178   | NO V à N1                                  | U 11 )   |  |
| V_34L0                               | 109   | N0 V Loc N1                                | N1 V Prép N0; Prép0 =: de                      |  |
| V_35L                                | 94    | N0 V Loc N1 source                         | 1 / 187 17                                     |  |
|                                      |       | Loc N2 destination                         |  |  |
| V_35LD                               | 74    | N0 V Loc N1 destination                    | N1 lieu de destination de N0                   |  |
| V_35LR                               | 169   | N0 V Loc N1                                | N1 = où  |  |
| V_35LS                               | 24    | N0 V Loc N1 source                         | N1 lieu source de N0 {Loc N1 =: de N1 source}  |  |
| V_35R                                | 514   | N0 V Prép N1                               |  |  |
| V_35RR                               | 33    | NO V Prép N1 Prép N2                       |  |  |
| V_35S                                | 125   | N0 V Prép N1                               | Prép1 =: avec; N0 et N1 V                      |  |
| V_35ST                               | 131   | N0 V Loc N1                                | N1 lieu statique de N0                         |  |
| V_39                                 | 90    | N0 V N1 N2                                 | ·  |  |

Table 6.1: Propriétés définitoires (vraies) des tables des verbes distributionnels (1)

| Tables    | Entr. | Construction de base                             | Autres propriétés définitoires   |  |
|-----------|-------|--|--|--|
| V_36DT    | 275   | NO V N1 Prép N2                                  | {N0 =: Nhum; N2 =: Nhum;   |  |
|           |       | ·  | Prép N2hum = Ppv =: lui}   |  |
| V_36R     | 93    | N0 V N1 à N2                                     | -  |  |
| V_36S     | 115   | N0 V N1 Prép N2                                  | N0 V N1 et N2  |  |
| V_36SL    | 106   | N0 V N1 Prép N2                                  | N0 V N1 et N2 {N0 V N1 Loc N2}   |  |
| V_37E     | 296   | N0 V N1 de N2                                    | $\{N0\;V\;N1\;de\;N2=N0\;enlever\;N2\;de\;N1\}$                                  |  |
| V_37M1    | 220   | N0 V N1 Prép N2                                  | Prép2 =: de; N1 bénéficiaire   |  |
|           |       |  | $\{N0\;V\;N1\;de\;N2=N0\;mettre\;N2\;Loc\;N1\}$                                  |  |
| V_37M2    | 129   | N0 V N1 Prép N2                                  | Prép2 =: de; N1 lieu de destination de N2  |  |
|           |       |  | N2 =: trace;   |  |
|           |       |  | N0 V N1 de N2 = N0 mettre N2 Loc N1 $\}$   |  |
| V_37M3    | 122   | N0 V N1 Prép N2                                  | Prép2 =: de; N1 lieu de destination de N2  |  |
|           |       |  | $\{N2 =: déformation;$   |  |
|           |       |  | N0 V N1 de N2 = N0 mettre N2 Loc N1 $\}$   |  |
| V_37M4    | 152   | N0 V N1 Prép N2                                  | Prép2 =: de; N1 lieu de destination de N2  |  |
|           |       |  | $\{N0\ V\ N1\ de\ N2 = N0\ mettre\ N2\ Loc\ N1\}$                                |  |
| V_37M5    | 198   | N0 V N1 Prép N2                                  | Prép2 =: de; N1 lieu de destination de N2  |  |
|           |       |  | $\{N2 =: N \text{ de V-n };$   |  |
| 77.053.50 | 200   |  | N0 V N1 de N2 = N0 mettre N2 Loc N1}   |  |
| V_37M6    | 283   | N0 V N1 Prép N2                                  | Prép2 =: de; N1 lieu de destination de N2  |  |
|           |       |  | {N2 =: V-n de N;   |  |
| N. OOT    | 100   | NO V/ NIT I NO                                   | N0 V N1 de N2 = N0 mettre N2 Loc N1}   |  |
| V_38L     | 123   | NO V N1 Loc N2 source                            | N1 =: N-hum; N2 lieu source de N1;   |  |
| V 20I 0   | 200   | Loc N3 destination                               | N3 lieu de destination de N1   |  |
| V_38L0    | 208   | NO V N1  | N1 =: N-hum  |  |
| V_38L1    | 164   | N0 V N1<br>N0 V N1 Loc N2 destination            | N1 =: N-hum  |  |
| V_38LD    | 340   | NO V N1 Loc N2 destination NO V N1 Loc N2 source | N1 =: N-hum; N2 lieu de destination de N1  |  |
| V_38LH    | 31    | N3 destination                                   | N2 lieu source de N1 ;   |  |
| V_38LHD   | 113   | NO V N1 Loc N2 destination                       | N3 lieu de destination de N1 {N1 =: Nhum}  |  |
| V_38LHR   | 72    | NO V N1 Loc N2 destination                       | N2 lieu de destination de N1 {N1 =: Nhum}  |  |
| V_38LHS   | 63    | NO V N1 Loc N2 source                            | N2 lieu statique de N1 $\{N1 =: Nhum\}$<br>N2 lieu source de N1 $\{N1 =: Nhum\}$ |  |
| V_38LR    | 284   | NO V N1 Loc N2 source                            | N1 =: N-hum; N2 lieu statique de N1  |  |
| V_38LS    | 173   | NO V N1 Loc N2 source                            | N1 =: N-hum; N2 lieu statique de N1 N1 =: N-hum; N2 lieu source de N1            |  |
| V_38PL    | 107   | NO V N1 LOC N2 Source                            | N2 =: Npl obl  |  |
| V_38R     | 342   | NO V N1 en N2<br>NO V N1 Prép N2                 | 142 —. 14pi obi  |  |
| V_38RR    | 18    | NO V N1 Prép N2<br>NO V N1 Prép N2 Prép N3       |  |  |
| N -99UU   | 10    | IND A INT Lieb INS Lieb INS                      |  |  |

Table 6.2: Propriétés définitoires (vraies) des tables des verbes distributionnels (2)

| Tables   | Entr. | Construction de base           | Autres propriétés définitoires                  |  |
|----------|-------|--------------------------------|---|--|
| N_aa     | 64    | N0 avoir Det N Prép N1         | N1 avoir Det N de N0                            |  |
| N_ad     | 74    | N0 donner Det N à N1           | INT AVOIL DELIN DE INO                          |  |
| N_an01   | 142   | N0 avoir Det N                 | N0 être de Det N Modif; N0 être Adj             |  |
| N_an02   | 154   | N0 avoir Det N                 | N0 être de Det N Modif; N0 être Adj             |  |
| N_an03   | 394   | N0 avoir Det N                 | N0 être de Det N Modif; N0 être Adj;            |  |
| 11241100 | 001   | TWO GVOIL BEETIN               | Det =: un-Modif                                 |  |
| N_an04   | 157   | N0 avoir Det N                 | N0 être de Det N Modif; N0 être Adj;            |  |
|          |       | 1                              | Det =: un-Modif                                 |  |
| N_an05   | 240   | N0 avoir Det N                 | N0 être de Det N Modif; N0 être Adj             |  |
| N_an06   | 276   | /                              | N0 être Adj                                     |  |
| N_an07   | 379   | N0 avoir Det N                 | Det =: un-Modif; Det =: un-certain              |  |
| N_an08   | 617   | N0 avoir Det N                 | Vsup =: comporter; Vsup =: comprendre           |  |
| N_an09   | 270   | N0 avoir Det N                 |   |  |
| N_an10   | 489   | N0 avoir Det N                 |   |  |
| N_andn   | 60    | N0 avoir Det N de N1           |   |  |
| N_ansn   | 49    | N0 avoir Det N sur N1          |   |  |
| N_ansy   | 24    | N0 avoir Det N Prép N1         | N0 et N1 avoir Det N; N0 être de Det N Prép N1; |  |
|          |       |                                | N0 être Adj Prép N1; N0 et N1 être Adj          |  |
| N_dr1    | 234   | N0 donner Det N à N1           | N1 recevoir Det N (de+de la part de) N0         |  |
| N_dr2    | 353   | N0 donner Det N à N1           | N1 recevoir Det N (de+de la part de) N0         |  |
| N_dr3    | 385   | N0 donner Det N à N1           | N1 recevoir Det N (de+de la part de) N0         |  |
| N_drc    | 106   | N0 donner un coup de N à N1    | N1 recevoir un coup de N (de+de la part de) N0  |  |
| N_es     | 90    | N0 exercer Det N Prép N1       | N1 subir Det N (de+de la part de) N0            |  |
| N_f1a    | 30    | N0 faire Det N                 |   |  |
| N_f1b    | 57    | N0 faire Det N                 |   |  |
| N_f1c    | 96    | N0 faire Det N                 |   |  |
| N_f1d    | 3     | N0 faire Det N                 |   |  |
| N_f1r    | 44    | N0 faire Det N                 |   |  |
| N_f21    | 102   | N0 faire Det N Prép N1         | Prép1 =: de                                     |  |
| N_f2a    | 379   | N0 faire Det N de N1           |   |  |
| N_f2b    | 40    | N0 faire Det N de N1           |   |  |
| N_f2b1   | 65    | N0 faire Det N de N1           |   |  |
| N_f2c    | 14    | N0 faire Det N de N1           |   |  |
| N_f2r    | 52    | N0 faire Det N de N1           |   |  |
| N_f3     | 83    | N0 faire Det N Prép N1         |   |  |
| N_f31    | 102   | N0 faire Det N Prép N1         |   |  |
| N_f4     | 14    | N0 faire Det N à N1            | N0 =: Nnr                                       |  |
| N_f41    | 11    | N0 faire Det N à N1            | N0 =: Nnr                                       |  |
| N_f5     | 237   | N0 faire Det N Prép N1         |   |  |
| N_f6     | 119   | N0 faire Det N de N1 Prép N2   |   |  |
| N_f7     | 52    | N0 faire Det N entre N1 et N2  |   |  |
| N_f8     | 43    | N0 faire Det N Prép N1 Prép N2 |   |  |
| N_f9     | 127   | N0 faire Det N de N1           | N0 =: Nnr; Det =: le                            |  |
| N_f91    | 39    | N0 faire Det N de N1           | N0 =: Nnr; Det =: le                            |  |

Table 6.3: Propriétés définitoires (vraies) des tables des noms prédicatifs (1)

| Tables  | Entr. | Construction de base   | Autres propriétés définitoires                    |
|---------|-------|------------------------|---|
| N_fn    | 373   | N0 faire Det N         |   |
| N_fna   | 191   | N0 faire Det N         |   |
| N_fnan  | 246   | N0 faire Det N à N1    | N0 faire Det N                                    |
| N_fnana | 45    | N0 faire Det N à N1    | NO faire Det N                                    |
| N_fnann | 90    | N0 faire Det N à N1    | N0 faire Det N                                    |
| N_fndn  | 194   | N0 faire Det N de N1   | 110 14.110 200 11                                 |
| N_fnn   | 248   | N0 faire Det N         |   |
| N_fnpn  | 414   | N0 faire Det N Prép N1 | N0 faire Det N                                    |
| N_fnpna | 75    | N0 faire Det N Prép N1 | N0 faire Det N                                    |
| N_fnpnn | 140   | N0 faire Det N Prép N1 | N0 faire Det N                                    |
| N_fr1   | 111   | N0 faire Det N Prép N1 | N1 recevoir Det N (de+de la part de) N0           |
| N_fr2   | 119   | N0 faire Det N Prép N1 | N1 recevoir Det N (de+de la part de) N0           |
| N_fr3   | 166   | N0 faire Det N Prép N1 | N1 recevoir Det N (de+de la part de) N0           |
| N_fs1   | 1 295 | N0 faire Det N Prép N1 | N1 subir Det N (de+de la part de) N0              |
| N_fs2   | 107   | N0 faire Det N Prép N1 | N1 subir Det N (de+de la part de) N0              |
| N_fs3   | 91    | N0 faire Det N Prép N1 | N1 subir Det N (de+de la part de) N0              |
| N_is1   | 44    | N0 infliger Det N à N1 | N1 subir Det N (de+de la part de) N0              |
| N_is2   | 112   | N0 infliger Det N à N1 | N1 subir Det N (de+de la part de) N0              |
| N_ans   | 257   | N0 Vsup Det N avec N1  | N0 et N1 Vsup Det N                               |
| N_ana   | 214   | NO Vsup Det N Prép N1  | Prép1 =: à  |
| N_anml  | 261   | N0 Vsup Det N Loc N1pc | - 10 - 10 - 10 - 10 - 10 - 10 - 10 - 10           |
| N_anm   | 121   | N0 Vsup Det N          |   |
| N_anmr  | 69    | N0 Vsup Det N          |   |
| N_ansu  | 142   | N0 Vsup Det N sur N1   |   |
| N_anp   | 64    | N0 Vsup Det N pour N1  |   |
| N_anpr  | 52    | N0 Vsup Det N Prép N1  |   |
| N_ape1  | 49    | N0 avoir Det N         | Vsup =: perdre; Vsup =: conserver; Vsup =: garder |
| N_ape11 | 33    | N0 avoir Det N         | N0 =: Nhum; Vsup =: perdre                        |
| N_ape2  | 68    | N0 avoir Det N Prép N1 | Vsup =: perdre                                    |
| N_ape21 | 45    | N0 avoir Det N de N1   | N1 avoir Det N Prép N0; N1 =: Nhum;               |
| _       |       |                        | Vsup =: perdre; Vconv =: perdre                   |
| N_ape22 | 56    | N0 avoir Det N de N1   | N1 Vconv Det N à N0; N1 =: Nhum; Vsup =: perdre;  |
|         |       |                        | Vsup =: conserver; Vsup =: garder                 |
| N_ape3  | 158   | N0 avoir Det N Prép N1 | N0 avoir Det N; Vsup =: perdre                    |
| N_app1  | 287   | N0 avoir Det N         | Vsup =: perdre; Vsup =: prendre                   |
| N_app2  | 65    | N0 avoir Det N Prép N1 | Vsup =: perdre; Vsup =: prendre                   |
| N_app3  | 83    | N0 avoir Det N Prép N1 | N0 avoir Det N; Vsup =: perdre; Vsup =: prendre   |
| N_psy   | 165   | N0 être en N Prép N1   |   |
| N_sym   | 180   | N0 être en N Prép N1   | N0 et N1 être en N                                |

TABLE 6.4: Propriétés définitoires (vraies) des tables des noms prédicatifs (2)

| Tables      | Entr. | Construction de base                             | Autres propriétés définitoires |
|-------------|-------|--|--------------------------------|
| C_31i       | 51    | C0 V W   | C0 = : ça                      |
| C_a1        | 586   | N0 avoir Det1 C1 Prépc Detc Cc                   | ,                              |
| C_a12       | 133   | N0 avoir Det1 C1 Adj1                            |                                |
| C_a1p2      | 603   | N0 avoir Det1 C1 Prép2 Det2 C2                   |                                |
| C_a1pn      | 207   | N0 avoir Det1 C1 Prép2 N2                        |                                |
| C_anp2      | 104   | N0 avoir N1 Prép2 Det2 C2                        |                                |
| C_c0        | 1 892 | Det0 C0 V Prép1 (Det1 C1+N1) Prép2 N2            |                                |
| C_c0e       | 702   | Conj Prép0 Det0 C0 Prép1 (Det1 C1+N1) Prép2 N2   |                                |
| C_c0q       | 405   | Det0 C0 V Prép1 (Det1 C1+N1) Prép2 N2            |                                |
| C_c1d       | 1 662 | N0 V Det1 C1                                     | Det1 =: déf                    |
| C_c1dpn     | 552   | N0 V Det1 C1 Prép2 N2                            | Det1 =: déf                    |
| C_c1g       | 671   | N0 V Poss1 C1                                    |                                |
| C_c1gpn     | 404   | N0 V Poss1 C1 Prép2 N2                           |                                |
| C_c1i       | 1 731 | N0 V Det1 C1                                     | Det1 =: indéf                  |
| C_c1ipn     | 938   | N0 V Det1 C1 Prép2 N2                            | Det1 =: indéf                  |
| C_c1p2      | 1 200 | N0 V Det1 C1 Prép2 Det2 C2                       |                                |
| C_c1r       | 589   | N0 V Det1 C1                                     |                                |
| C_c1rpn     | 549   | N0 V Det1 C1 Prép2 N2                            |                                |
| $C_c5$      | 121   | N0 V Prép1 Det1 C1 de Nc                         | N0 =: Qu P                     |
| C_c5c1      | 104   | N0 V Prép1 Det1 C1                               | N0 =: Qu P                     |
| C_c6        | 354   | N0 V N1 Prép2 Det2 C2                            |                                |
| C_c7        | 185   | N0 V Det1 C1 à N2                                |                                |
| C_c8        | 371   | N0 V Det1 C1 de N2                               |                                |
| C_cadv      | 407   | N0 V Modif Adv1                                  |                                |
| C_can       | 895   | N0 V Det1 C1 à Nc                                | N0 V Det1 C1 de Nc             |
| C_cdn       | 855   | N0 V Det1 C1 de Nc                               |                                |
| C_cff       | 206   | Conj (Det0 C0+N0) V (Det1 C1+N1) Conj-2 Det0-2   |                                |
|             |       | C0-2 V-2 Det1-2 C1-2                             |                                |
| C_cnp2      | 2 051 | N0 V N1 Prép2 Det2 C2                            |                                |
| C_cp1       | 2 116 | N0 V Prép1 Det1 C1                               |                                |
| C_cpn       | 396   | N0 V Prép1 Det1 C1 de Nc                         |                                |
| C_cpp       | 264   | N0 V Prép1 Det1 C1 Prép2 (Det2 C2+N2)            |                                |
| C_cppn      | 387   | N0 V Prép1 (Det1 C1+N1) Prép2 (Det2 C2+N2) Prép3 |                                |
|             |       | (Det3 C3+N3)                                     |                                |
| C_cppq      | 420   | N0 V Prép1 (Det1 C1+N1) Prép2 Det2 C2 Prép3 N3   |                                |
| C_cpq       | 322   | N0 V Prép1 Det1 C1 Prép2 N2                      |                                |
| C_cv        | 434   | N0 V Prép1 (Det1 C1+N1) V2 Prépv (Detv Cv+Nv)    |                                |
| C_e01       | 3 043 | Det0 C0 être Adj1                                |                                |
| $C_{-}e0p1$ | 651   | Det0 C0 être Prép1 Det1 C1                       |                                |
| C_e1        | 280   | N0 être Det1 C1                                  |                                |
| C_e1hc      | 457   | N0 être Det1 C1 Prépc Detc Cc                    | N0 =: Nhum                     |
| C_e1pn      | 289   | N0 être Det1 C1 Prépc Detc Cc Prép2 N2           |                                |
| C_eapc      | 1 304 | N0 être Adj1 Prépc Detc Cc                       |                                |
| C_ec0       | 456   | Ce être Prép1 Det1 C1 Prép2 Det2 C2              |                                |
| C_edn       | 781   | N0 être Det1 C1 de Nc                            |                                |
| C_enpc      | 630   | N0 être Det1 N1 Prépc Detc Cc                    |                                |

Table 6.5: Propriétés définitoires (vraies) des tables d'expressions figées (1)

| Tables   | Entr. | Construction de base                        | Autres propriétés définitoires   |
|----------|-------|---|----------------------------------|
| C_epa    | 661   | N0 être Adv1 Adj1                           |                                  |
| C_epac   | 743   | N0 être Prép1 Det1 Adj1 C1                  | Adj1 permut obl                  |
| C_epc    | 1 357 | N0 être Prép1 C1                            |                                  |
| C_epca   | 710   | N0 être Prép1 Det1 C1 Adj1                  |                                  |
| C_epcdc  | 953   | N0 être Prép1 Det1 C1 Prépc Detc Cc         |                                  |
| C_epcdn  | 933   | N0 être Prép1 Det1 C1 de Nc                 |                                  |
| C_epcpc  | 902   | N0 être Prép1 Det1 C1 Prép2 Det2 C2         |                                  |
| C_epcpn  | 910   | N0 être Prép1 Det1 C1 Prép2 N2              |                                  |
| C_epcpq  | 185   | N0 être Prép1 Det1 C1 Prép2 N2              |                                  |
| C_epdetc | 1 060 | N0 être Prép1 Det1 C1                       |                                  |
| C_fc     | 215   | N0 faire Det1 C1                            |                                  |
| C_fca    | 57    | N0 faire Det1 C1 Adj1                       |                                  |
| C_fcan   | 89    | N0 faire Det1 C1 à N2                       |                                  |
| C_fcana  | 18    | N0 faire Det1 C1 Adj1 à N2                  |                                  |
| C_fcann  | 6     | N0 faire Det1 C1 Prépc Detc Cc à N2         |                                  |
| C_fcn    | 30    | N0 faire Det1 C1 Prépc Detc Cc              |                                  |
| C_fcpn   | 88    | N0 faire Det1 C1 Prép2 N2                   |                                  |
| C_fcpna  | 25    | N0 faire Det1 C1 Adj1 Prép2 N2              |                                  |
| C_fcpnn  | 12    | N0 faire Det1 C1 Prépc Detc Cc Prép2 N2     |                                  |
| C_ya     | 351   | il y avoir Prép1 Det1 C1 Prép2 (Det2 C2+N2) |                                  |
|          |       | Prép3 N3                                    |                                  |
| C_z5d    | 38    | N0 être Prép1 Det1 C1 de N2                 | N0 =: Qu P;                      |
|          |       |   | il être Prép1 Det1 C1 de N2 Qu P |
| C_z5p    | 48    | N0 être Prép1 Det1 C1                       | N0 =: Qu P; Prép2 # de;          |
|          |       |   | il être Prép1 C1 Qu P            |
| C_z1     | 38    | N0 être Prép1 Det1 C1 de V0-inf W           | N2 =: Qu P                       |
| C_zs     | 91    | N0 être Prép1 Det1 C1 Prép2 N2              | N0 et N2 être Prép1 Det1 C1      |
| C_zp     | 50    | N0 être Prép1 Det1 C1 Prép2 N2              | Prép2 # de                       |

Table 6.6: Propriétés définitoires (vraies) des tables d'expressions figées (2)

| Tables   | Entr. | Structure de base de l'adverbe   | Constructions définitoires                  |
|----------|-------|----------------------------------|---|
| P_advmf  | 16    | Adv                              | N0 V Adv W                                  |
| P_advmp  | 279   | Adv                              | N0 V Adv W; Adv, N0 V W; Adv, N0 ne V pas W |
| P_advmqc | 13    | Adv                              | N0 V Adv W                                  |
| P_advmqe | 21    | Adv                              | N0 V Adv W                                  |
| P_advmqi | 247   | Adv                              | N0 V Adv W                                  |
| P_advms  | 883   | Adv                              | N0 V Adv W; Adv, N0 V W                     |
| P_advmtd | 11    | Adv                              | N0 V Adv W                                  |
| P_advmtf | 33    | Adv                              | N0 V Adv W; Adv, N0 V W                     |
| P_advmtq | 31    | Adv                              | N0 V Adv W                                  |
| P_advmv  | 1 523 | Adv                              | N0 V Adv W                                  |
| P_advpae | 10    | Adv                              | Adv, N0 V W; Adv, N0 ne V pas W             |
| P_advpah | 10    | Adv                              | Adv, N0 V W; Adv, N0 ne V pas W             |
| P_advpam | 28    | Adv                              | Adv, N0 V W; Adv, N0 ne V pas W             |
| P_advpas | 30    | Adv                              | Adv, N0 V W; Adv, N0 ne V pas W             |
| P_advpc  | 51    | Adv                              | Adv, N0 V W; Adv, N0 ne V pas W; P1 Adv P2  |
| P_advps  | 17    | Adv                              | Adv, N0 V W; Adv, N0 ne V pas W             |
| P_pac    | 776   | Prép Det Adj C                   | N0 V Adv W; Adv, N0 V W; Adv, N0 ne V pas W |
| P_padv   | 524   | Adv                              | N0 V Adv W; Adv, N0 V W; Adv, N0 ne V pas W |
| P_pc     | 664   | Prép C                           | N0 V Adv W; Adv, N0 V W; Adv, N0 ne V pas W |
| P_pca    | 840   | Prép Det C Modif pré-adj Adj     | N0 V Adv W; Adv, N0 V W; Adv, N0 ne V pas W |
| P_pcdc   | 750   | Prép1 Det1 C1 Prép2 Det2 C2      | N0 V Adv W; Adv, N0 V W; Adv, N0 ne V pas W |
| P_pcdn   | 555   | Prép1 Det1 C1 Prép2 N2           | N0 V Adv W; Adv, N0 V W; Adv, N0 ne V pas W |
| P_pconj  | 332   | Prép1 Det1 C1 Conj Prép2 Det2 C2 | N0 V Adv W; Adv, N0 V W; Adv, N0 ne V pas W |
| P_pcpc   | 287   | Prép1 Det1 C1 Prép2 Det2 C2      | N0 V Adv W; Adv, N0 V W; Adv, N0 ne V pas W |
| P_pcpn   | 151   | Prép1 Det1 C1 Prép2 N2           | N0 V Adv W; Adv, N0 V W; Adv, N0 ne V pas W |
| P_pdetc  | 848   | Prép Det C                       | N0 V Adv W; Adv, N0 V W; Adv, N0 ne V pas W |
| P_peco   | 304   | comme Det C                      | N0 V Adv W; Adv, N0 V W; Adv, N0 ne V pas W |
| P_pf     | 396   | ConjS (Det0 C0+N0) V Prép1       | N0 V Adv W; Adv, N0 V W; Adv, N0 ne V pas W |
|          |       | (Det1 C1+N1)                     |   |
| P_pjc    | 185   | ConjC Det C1 Prép C2             | N0 V Adv W; Adv, N0 V W; Adv, N0 ne V pas W |
| P_ppco   | 50    | comme Prép Det C                 | N0 V Adv W; Adv, N0 V W; Adv, N0 ne V pas W |
| P_pv     | 285   | Prép V Prépv Detv Cv             | N0 V Adv W; Adv, N0 V W; Adv, N0 ne V pas W |
|          |       | (ou Prép Prépv Detv Cv V)        |   |
| P_pvco   | 338   | comme Det C                      | N0 V Adv W; Adv, N0 V W; Adv, N0 ne V pas W |

Table 6.7: Propriétés définitoires (vraies) des tables d'adverbes

#### 6.6.3 Conclusion

Nous avons vu que les modifications concernant les constructions de base sont diverses :

- certaines propriétés distributionnelles accompagnant la construction de base étaient manquantes;
- la notation + dans les constructions de base a été au maximum supprimée pour éviter les interprétations ambiguës;
- certaines colonnes ont été dupliquées pour rendre compte des informations implicites de certaines classes de symétriques;
- le code des compléments des constructions de base de certaines classes de locatifs a été modifié (par exemple, remplacement de Loc N1 par Loc N1 source et Loc N2 destination), ce qui a impliqué une division des classes;
- des colonnes ont été ajoutées pour rendre compte de certains cas, comme par exemple les sources dépendantes;
- de nouvelles classes ont été créées;
- des colonnes ont été renommées pour être reliées à la construction de base;
- certaines classes acceptaient à l'origine deux constructions de base mais une seule a été retenue;
- des colonnes entièrement codées + ont parfois été supprimées pour faire partie des propriétés définitoires;
- certaines approximations ont été faites lorsqu'il n'existait pas de construction de base;
- pour les entrées figées (expressions et adverbes (semi-)figés), la structure morphosyntaxique interne de l'entrée a été définie.

Après avoir défini les constructions de base pour chaque classe dans toutes les catégories (verbes distributionnels, noms prédicatifs, expressions figées et adverbes), cela nous a permis de construire un lexique très riche et d'envisager une utilisation de ces données lexicales dans des outils de traitement automatique, notamment un analyseur syntaxique, comme nous allons le voir par la suite.

# Troisième partie Conversion des tables

# 7

### Conversion au format LGLex

Ce chapitre est organisé comme suit. Nous commençons par présenter les motivations de ce travail dans la section 7.1, la version actuelle des tables permettant d'envisager une utilisation de ces données lexicales dans des outils de TAL (Tolone, 2009). Ensuite, nous proposons l'outil générique, nommé LGExtract, qui permet de générer un lexique syntaxique pour le TAL à partir des tables du Lexique-Grammaire dans la section 7.2, comme nous l'avons présenté dans Constant et Tolone (2010). Nous expliquons le format du lexique LGLex généré pour l'ensemble des catégories, en l'illustrant avec des exemples concrets en français dans la section 7.3, comme nous l'avons initialement fait pour les verbes et les noms (Constant et Tolone, 2010). Puis, nous détaillons le script utilisé pour créer le lexique dans la section 7.4. Enfin, nous discutons des avantages et inconvénients de l'outil LGExtract dans la section 7.5.

#### 7.1 Motivations

Un des obstacles à l'utilisation des tables du Lexique-Grammaire en TAL est son degré de formalisation. Il est plus formalisé que le TLFi (Dendien et Pierrel, 2003), dans lequel les propriétés syntaxico-sémantiques sont décrites par du texte ou suggérées par des exemples, et non spécifiées par des intitulés normalisés; mais il l'est moins que les lexiques utilisés par les analyseurs syntaxiques. Nous présentons les travaux précédents (7.1.1) ayant essayé d'utiliser les tables du Lexique-Grammaire pour l'analyse syntaxique, pour ensuite justifier l'intérêt de notre méthode en introduisant l'outil que nous avons créé, tout en spécifiant sa particularité (7.1.2).

#### 7.1.1 Travaux précédents

Dans les années 2000, les projets LexSynt et LMF (Francopoulo et al., 2006) ont suscité chez les spécialistes de l'analyse syntaxique un renouveau de l'intérêt pour les tables du Lexique-Grammaire. Cela a motivé la recherche de solutions à son insuffisance de formalisation, notamment à travers l'utilisation de réseaux de transitions récursifs (Paumier, 2003; Blanc, 2006). Cependant, le nombre de graphes explose rapidement. Une autre solution envisagée est d'utiliser des formules plus précises que les intitulés, mais elles ne sauraient être aussi concises que ceux-ci (cf. 5.2.1) : la solution n'est donc pas de simplement substituer ces formules aux intitulés, qui gardent leur raison d'être. D'autres (Gardent et al., 2005) préconisent que les informations des tables du Lexique-Grammaire soient rendues utilisables dans des systèmes de traitement des langues par un pré-traitement, qui les ferait passer à un niveau de formalisation équivalent à celui de la norme LMF, et éventuellement soient encodées en XML.

C'est de cette manière que certains travaux (Hathout et Namer, 1998; Gardent et al., 2006; Sagot et Danlos, 2007; Danlos et Sagot, 2008) ont tenté de reformater les tables du Lexique-Grammaire en un lexique syntaxique pour le TAL. Dans ces travaux, à chaque classe est attribué un fichier de configuration spécifique, qui code les informations manquantes et définie les opérations de restructuration. Ainsi, chaque fichier de configuration dans Gardent et al. (2006) est représenté par un graphe qui rend la structure de la classe explicite et traduit chaque intitulé de colonne en une structure de traits. Cependant, les tables du Lexique-Grammaire sont continuellement mises à jour pour être améliorées (par exemple, l'ajout ou le renommage de propriétés), ce qui rend cette approche pénible à maintenir. Par exemple, si une même propriété est ajoutée dans plusieurs classes, tous les fichiers de configuration doivent être modifiés.

Cette constatation nous a orienté vers la création de *LGExtract* (Constant et Tolone, 2010)<sup>1</sup>, un outil qui utilise une approche globale. D'abord, il est relié à la table des classes, qui code les informations qui ne sont pas définies dans les classes d'origine, particulièrement les propriétés qui sont constantes pour l'ensemble d'une classe. Ensuite, comme une propriété syntaxique a exactement une interprétation pour l'ensemble des classes, notre script d'extraction assigne une seule fois pour chaque propriété un ensemble d'opérations.

Ainsi, nous transcodons les informations des tables du Lexique-Grammaire sous la forme d'ensembles de structures de traits (comparables à celles vu en 5.2.1), dont le format est présenté dans la section 7.3.

Ce qui prime dans cette approche c'est de garder les tables sous leur format tabulaire original pour l'édition manuelle, et ensuite de les convertir dans un lexique syntaxique utilisable en TAL, nommé *LGLex*. Ce traitement permet de relier entre elles les propriétés qui contribuent à décrire une même construction. Par exemple, si l'on prend la construction N0 V à N1 et la propriété distributionnelle N0 =: Nhum : les tables du Lexique-Grammaire elles-mêmes ne les relient pas explicitement, si ce n'est à travers le symbole N0 contenu dans les deux intitulés. Dans cet exemple, on pourrait utiliser l'inti-

<sup>1.</sup> Disponible sur le site http://infolingu.univ-mlv.fr/ (Données Linguistiques > Lexique-Grammaire > Téléchargement).

tulé N0hum V à N1, comme nous l'avons expliqué en 5.2.2. Mais si l'on souhaite également accepter la propriété distributionnelle N0 =: N-hum, il n'est pas possible de le spécifier dans les tables avec un seul intitulé succinct, or c'est précisément ce que permettent de faire les structures de traits.

#### 7.1.2 Particularité de l'outil LGExtract

LGExtract a vocation à transformer les tables en un lexique syntaxique pour le TAL, reposant sur les mêmes concepts linguistiques que ceux qui sont à l'œuvre dans les tables. C'est-à-dire que le format du lexique LGLex est ce qu'on appelle un format d'échange. Il a vocation à décrire les tables avec les concepts manipulés par celles-ci, en un format directement exploitable dans les applications de TAL. L'une des utilisations informatiques possibles est la conversion en un autre format, par exemple au format Lefff, ce qui suppose de manipuler d'autres concepts linguistiques, ceux manipulés par le Lefff.

En effet, contrairement à *LGLex*, qui liste toutes les constructions acceptées par une entrée telles qu'elles existent dans les tables, le *Lefff* regroupe dans une représentation unique des constructions qu'il considère comme étant des variantes l'une de l'autre. Ainsi, l'effacement d'un argument dans une construction est considéré comme une variante de cette construction. Cette représentation est adaptée pour certains formalismes d'analyseurs syntaxiques, tel que TAG utilisé dans l'analyseur FRMG et LFG dans l'analyseur SxLFG (cf. 2.1.3).

Il y a donc deux étapes bien distinctes, puisqu'il ne semble pas souhaitable que le format LGLex manipule des concepts issus du Lefff ou de DICOVALENCE : le format LGLex doit être utilisable par tous les connaisseurs des tables du Lexique-Grammaire, y compris ceux qui refusent totalement la notion de fonction syntaxique (du Lefff) ou de paradigme (de DICOVALENCE). La construction du lexique LGLex n'a rien à voir avec ses utilisations, comme par exemple sa conversion en un autre format.

LGExtract se concentre sur l'explicitation de certaines colonnes, sans utiliser d'autres concepts que ceux des tables du Lexique-Grammaire. On obtient ainsi dans LGLex, une représentation plus explicite des tables, ce qui sert (entre autres) à produire plus simplement une représentation au format Lefff.

#### **7.2 L'outil** *LGExtract*

Les propositions antérieures pour transformer les tables du Lexique-Grammaire en un lexique syntaxique pour le TAL consistaient en des paramètres spécifiques pour chaque classe : la sélection des propriétés pertinentes, l'ajout de propriétés manquantes et la restructuration de données (Hathout et Namer, 1998; Gardent et al., 2006). Comme plusieurs propriétés apparaissent dans plusieurs classes, la définition d'un même ensemble d'opérations peut ainsi se répéter dans plusieurs classes, ceci rendant cette approche pénible pour l'encodage et la maintenance.

Nous proposons une approche plus globale, en utilisant pour l'ensemble des classes d'une même catégorie les deux ressources suivantes :

- un script unique de configuration couvrant toutes les classes;
- une table des classes fournissant des informations non définies dans les classes d'origine.

Pour implémenter cette approche, nous avons développé en Java un outil générique nommé  $LGExtract^2$ , qui fonctionne de la manière suivante :

- il prend en entrée un script de configuration et une table des classes;
- il analyse ce script à l'aide d'un analyseur généré par l'outil Tatoo (Cervelle et al., 2006);
- il produit l'ensemble des entrées lexicales encodées dans les classes couvertes par la table des classes et dans le format décrit par le script.

Les deux instructions principales interprétées par notre outil sont les suivantes :

- define : l'information est encodée dans des objets linguistiques définis dans le script. Ils sont représentés par des listes et des structures de traits, qui peuvent être combinées. Ces objets définissent par exemple, des constituants syntaxiques, des distributions de constituants syntaxiques, des constructions, des représentations prédicat-argument, des transformations. Les objets peuvent être paramétrés par les propriétés syntaxiques disponibles dans la table des classes;
- prop : chaque propriété de la table des classes est associée à un ensemble d'opérations qui combinent les objets linguistiques entre eux. Ainsi, quand la propriété N0 =: Nhum est vraie pour une entrée donnée, un objet définissant un groupe nominal humain est ajouté à la distribution de N0 (c'est-à-dire l'argument 0 du prédicat).

Cela implique que chaque propriété a une et une seule interprétation pour toutes les classes, si tel n'était pas le cas, notre outil fournirait des informations incorrectes.

Un objet linguistique est constitué de listes et de structures de traits. Une instance d'un tel objet est définie par l'instruction **define**, en indiquant son type, son nom et sa valeur. Par exemple, les instructions ci-dessous instancient chacune un composant (**comp**) nommé N-hum, qui est un groupe nominal non humain, un groupe nominal humain (Nhum), une complétive au mode indicatif (Qu Pind), une complétive au mode subjonctif (Qu Psubj) ou une infinitive (V-inf W) :

```
define comp N-hum [cat="NP",nothum="true"];
define comp Nhum [cat="NP",hum="true"];
define comp completive [cat="comp",mood="ind"];
define comp completiveSubj [cat="comp",mood="subj"];
define comp inf [cat="inf"];
```

Ces différents objets peuvent être combinés : par exemple, la distribution d'un constituant (**const**) est un ensemble de composants syntaxiques. Dans l'instruction ci-dessous, le constituant **N0** contient la distribution de l'argument 0 :

<sup>2.</sup> Il est composé de 118 fichiers *.java* et est disponible sur le site http://infolingu.univ-mlv.fr/ (Données Linguistiques > Lexique-Grammaire > Téléchargement).

```
define const NO [pos="0",dist=()];
```

avec dist() qui pourra contenir un groupe nominal humain (Nhum) et un groupe nominal non humain (N-hum)<sup>3</sup>:

```
comp=[cat="NP",nothum="true"],comp=[cat="NP",hum="true"]
```

Comme dans tout langage orienté objet, un mécanisme d'héritage existe. Par exemple, une infinitive contrôlée par l'argument 0 (objet **inf0**) hérite des traits de l'objet **inf** (définissant une infinitive) décrit ci-dessus, et possède un trait supplémentaire indiquant le contrôle par l'argument 0 :

```
define comp inf0 inf[contr="0"];
```

Tous ces objets peuvent être paramétrés avec les propriétés de la table des classes (notation @...@). Les paramètres sont de deux types : booléen ou chaîne de caractères. Par exemple, le code ci-dessous définit un prédicat verbal nommé **predV**, en l'ajoutant dans les informations lexicales liées à l'entrée (**lexical-info**). Son lemme est la valeur de la propriété <ENT>V (c'est-à-dire la valeur lexicale d'une entrée) dans la classe correspondante. Le code définit ensuite l'auxiliaire avoir (respectivement, être), où la propriété Aux =: avoir (respectivement, Aux =: être) est encodée par sa valeur booléenne :

```
define lexical-info predV [cat="verb",verb=[lemma="@<ENT>V@"],aux-list=()];
define aux avoir {avoir="@Aux =: avoir@"};
define aux etre {être="@Aux =: être@"};
```

Pour chaque entrée lexicale, les paramètres des objets linguistiques associés sont établis comme suit. Chaque paramètre, correspondant à une propriété, possède une valeur lexicale ou booléenne. Le programme parcourt d'abord la table des classes. Si la propriété a une valeur constante sur toute la classe à laquelle l'entrée appartient, la propriété reçoit cette valeur. Si la valeur de la propriété est variable selon les entrées lexicales (la valeur de la propriété est o pour la ligne correspondant à cette classe), le programme récupère la valeur de la propriété de cette entrée dans la classe concernée. Par exemple, le verbe alarmer appartient à la classe 32H, qui contient les verbes transitifs avec sujet humain : @<ENT>V@ est donc remplacé par la valeur lexicale alarmer, ce qui permet de savoir de quel lemme il s'agit pour cette entrée. La propriété Aux =: avoir est codée + dans la table pour ce verbe : @Aux = : avoir@ est remplacé par true. En revanche, la propriété Aux =: être est codée -, donc le programme ne récupère pas cette information (voir plus loin). Les trois objets paramétrés montrés ci-dessus deviennent alors les deux objets suivants pour cette entrée :

```
define lexical-info predV [cat="verb",verb=[lemma="alarmer"],aux-list=()];
define aux avoir {avoir="true"};
```

<sup>3.</sup> Nous verrons plus loin que cela est obtenu grâce à l'opération d'ajout : add N0-hum in N0.dist; add N0hum in N0.dist;

Ainsi, si une contradiction survient entre la table des classes et une classe particulière, la priorité est donnée à l'encodage de la table des classes.

Pour chaque entrée lexicale, le programme peut ensuite appliquer des opérations pour chaque propriété de la table des classes à ces objets lexicalisés, avec l'instruction **prop**. Il y a seulement un type d'opération : l'ajout (add) d'un objet à un autre. Par exemple, l'ajout d'une paire attribut-valeur ou d'une liste dans une structure de traits. Ces opérations sont indépendantes de leur ordre d'application, c'est-à-dire qu'elles sont non destructrices et ne dépendent pas les unes des autres. Ainsi, lors de l'insertion d'une paire attribut-valeur (a,v) dans une structure de traits, si une autre valeur ov pour l'attribut a existe déjà, la nouvelle valeur est une disjonction de v et ov. C'est pourquoi l'opération est dite non destructrice. Les listes sont en fait des ensembles car le résultat des deux additions doit être indépendant de leur ordre d'application. Avant d'insérer un nouvel élément dans une liste, le programme vérifie s'il existe ou non. S'il existe, il n'est pas inséré. Par exemple, le code suivant indique que, si la propriété NO =: Nor (signifiant que NO0 est un groupe nominal libre, une complétive ou une infinitive) est codée +, le programme ajoute les objets N-hum, Nhum, completive, completiveSubj et inf à la distribution de NO0 (NO.dist) et insère NO0 dans la liste des arguments (args):

```
prop @NO =: Nnr@{
  add NO in args;
  add NO-hum in NO.dist;
  add NOhum in NO.dist;
  add completive in NO.dist;
  add completiveSubj in NO.dist;
  add inf in NO.dist;
}
```

Si la propriété est codée — (que ce soit dans la table des classes ou dans la table), aucune opération n'est réalisée. En effet, pour chaque entrée, seules sont effectuées les opérations concernant les propriétés acceptées par l'entrée. C'est ce qui permet dans l'exemple précédent d'ajouter dans le lexique (dans la liste aux-list de predV) l'objet paramétré avoir="@Aux = : avoir@", sans le faire pour être="@Aux = : être@", avec le code suivant :

```
prop @Aux =: avoir@{
   add avoir in predV.aux-list;
}
prop @Aux =: être@{
   add etre in predV.aux-list;
}
```

Le lexique généré est au format XML. Les éléments et attributs XML peuvent être mis en correspondance dans le script avec les objets linguistiques. Ce lexique XML étant quasiment illisible par un humain, une version texte compressée a été également développée (voir les exemples de la section 7.3).

#### 7.3 Le lexique LGLex

Grâce à *LGExtract* et à tous les travaux de mise en cohérence et d'explicitation des propriétés syntaxiques vus aux chapitres 5 et 6, il a été possible de construire un lexique syntaxique du français pour le TAL : *LGLex* (Constant et Tolone, 2010). Il a été généré à partir des tables du Lexique-Grammaire librement distribuées de toutes les catégories, à savoir les verbes distributionnels, les noms prédicatifs, les expressions figées et les adverbes. Il est également librement distribué sous licence LGPL-LR (http://infolingu.univ-mlv.fr, Données Linguistiques > Lexique-Grammaire > Téléchargement). Les détails pour pouvoir générer le lexique *LGLex* sont expliqués dans l'annexe B.

Il est composé de 13 867 entrées verbales (provenant de 67 tables), de 12 696 entrées nominales (provenant de 78 tables), de 39 628 expressions figées principalement verbales et adjectivales (provenant de 69 tables) et de 10 488 entrées adverbiales (provenant de 32 tables) <sup>4</sup>. De plus, il contient comme entrées secondaires : 3 334 entrées verbales (provenant de 24 tables de noms prédicatifs), 1 408 entrées adjectivales (provenant de 8 tables de noms prédicatifs), 388 expressions figées verbales (provenant de 2 tables d'adverbes) et 304 entrées adjectivales (provenant d'une table d'adverbes).

Le script d'extraction (présenté dans la section 7.4) encode seulement une sélection de propriétés, certaines ayant été éliminées car elles ne sont pas exploitables. C'est ainsi que nous avons éliminé les propriétés concernant les noms dérivés de verbes (V-n) sans information explicite sur la procédure de dérivation<sup>5</sup>. De même, certaines propriétés concernant des traits sémantiques tels que les noms de parties du corps, le sens métaphorique de la phrase (esprit, idée, mot, texte), etc. n'ont pas été jugées pertinentes. Prenons comme exemple la propriété N2 =: déformation de la table 37M3, indiquant que l'objet N2 peut dénoter le type de déformation subit par l'objet N1, comme dans La pluie a sillonné le terrain de crevasses. Il faudrait donc établir une liste précise de tous les noms désignant une déformation, ce qui n'est pas évident car les critères ne sont pas clairement définis. Ainsi, les noms trou, creux, cavité, etc. sont des synonymes de crevasse dans l'exemple précédent. Mais si l'on prend l'exemple Cet accident a couturé son visage de cicatrices, on doit tenir compte des noms comme brûlure, ride, balafre, etc. qui sont des déformations du corps humain. Enfin, l'exemple Max a altéré son texte d'annotations illustre la difficulté d'établir une liste exhaustive, puisque le mot annotation est loin de désigner une déformation, ce qui pourtant ce révèle être vrai dans l'exemple précédent. En effet, comme nous l'avons mentionné en 6.2.2, les critères sémantiques ou morphologiques justifiant le découpage des tables 37M2 à 37M6 ne sont pas définissables clairement et n'ont pas la moindre reproductibilité.

Dans le lexique LGLex, les informations syntaxiques sont représentées de façon par-

<sup>4.</sup> Les entrées ne sont autres que celles des tables, le nombre de lemmes distincts est donc également le même (voir la section 6.6).

<sup>5.</sup> De plus, malgré le codage de certaines informations concernant les V-n dans les tables de verbes (Paumier, 2003), la reconnaissance des V-n est un problème compliqué qui soulève de nombreuses interrogations pour l'instant sans réponse.

tiellement formalisée. Dans sa version textuelle, une entrée de LGLex se présente comme suit :

- l'entrée commence par un identifiant indiquant sa catégorie, la table dont il provient et le numéro de l'entrée dans cette table (ID=catégorie\_numTable\_numEntrée), suivi du statut completed pour une entrée entièrement codée, to complete pour une entrée qui a au moins une propriété non codée <sup>6</sup> ou to encode pour une entrée qui a au moins la moitié de ses propriétés non codées <sup>7</sup>;
- la section **lexical-info** indique les informations lexicales liées à l'entrée :
  - le lemme (correspondant à l'entrée complète, qu'elle soit simple ou composée), et pour les entrées composées, les différents mots de l'entrée associés à leur catégorie grammaticale, ainsi que pour certaines entrées nominales, l'adjectif ou le verbe morphologiquement dérivé du nom;
  - mais également les auxiliaire(s) pour les entrées verbales, les verbes supports et les déterminants pour les entrées nominales, et les prépositions associées à certains arguments. Les prépositions possibles à la place de l'indication Prép (respectivement, Loc) sont dans la partie prépositions (respectivement, locs);
- la section **args** décrit les distributions des différents arguments (sujet et compléments, répartis en sous-sections **const** dont la position est repérée par l'élément **pos**). Une distribution donnée (élément **comp**) indique :
  - sa catégorie grammaticale : NP pour un syntagme nominal, inf pour une infinitive (V-inf W), comp pour une complétive (Qu P), leFaitComp pour le groupe nominal le fait que P, siPOuSiP pour la complétive si P ou si P, adj pour un adjectif;
  - son introducteur (élément introd-prep ou introd-loc);
  - des traits sémantiques : hum, nothum, plobl (pluriel obligatoire), npr
     (nom propre), abst (abstrait), conc (concret), source, destination, benef
     (bénéficiaire), mesure, prix, coll (collectif), plur (pluriel);
  - des traits complémentaires (mood dans le cas d'une complétive, contrl dans le cas d'une infinitive);
  - l'intitulé complet des propriétés distributionnelles ayant contribué à définir cette distribution, qui sont toutes de la forme argument =: réalisation. Cette information n'est là qu'à titre informatif, pour pouvoir faire le lien avec les tables d'origine.

Cette section est donc bien formalisée;

- la section **all-constructions** liste différentes constructions dans lesquelles l'entrée peut prendre part :
  - les constructions absolues (élément absolute) sont les constructions additionnelles à la construction de base, qui sont nommées de façon complète, avec tous les

<sup>6.</sup> On appelle ici une propriété non codée, une propriété présente dans la table et codée  $\sim$ . Cela ne tient pas compte du codage O dans la table des classes, qui signifie également que la propriété doit être codée, mais qui ne figure pas dans la table.

<sup>7.</sup> Le statut **to complete** permet de différencier ces entrées de celles entièrement codées (statut **complete**), leur codage doit donc être complété. Le statut **to encode** permet de repérer les entrées où seule la table des classes code certaines constantes et non la table concernée elle-même, il faut donc les coder entièrement. En effet, même si une entrée est codée entièrement ~, elle est difficilement détectable dans le lexique.

- éléments dans l'ordre (par exemple, N0 V N1);
- les constructions relatives (élément relative) sont les propriétés transformationnelles, qui correspondent aux redistributions (par exemple, [passif par]), pronominalisations (par exemple, Ppv =: y), etc.
- les réductions en groupe nominal (élément reductionsGN) sont pour les entrées nominales, les réductions de la construction de base vers une autre construction dans une autre catégorie syntaxique, dans le cas présent, un groupe nominal (par exemple, le N entre N0 et N1);
- les constructions verbales (élément verbales) sont les constructions acceptées par le verbe associé à une entrée nominale;
- les structures des adverbes (semi-)figés (élément structureAdv) définissent l'ordre des différents constituants d'une entrée adverbiale, ainsi que les possibles variantes (par exemple, Prép1 Det1 C1 Prép2 Det2 C2 et Prép1 Det1 C1, cf. 6.5.3).

Les constructions codées + (incluant la construction de base) dans la table des classes sont précédées de la mention **true**::, les autres sont précédées de la mention **o**::. Cette section est donc bien moins bien formalisée que la précédente, et les informations qu'elle contient ne sont pas directement exploitables informatiquement;

la section example illustre l'entrée.

Pour plus de détails, voir l'annexe A.

L'exemple ci-dessous montre un extrait du lexique LGLex pour l'entrée verbale se rendre de la table 33 des verbes (cf. Fig. 3.1)  $^8$ . La construction de base est N0 V à N1 et l'argument N1 est effaçable puisque l'entrée accepte également la construction N0 V à N1. L'argument N0 doit être un groupe nominal humain, alors que l'argument N1 peut être humain, non humain ou prendre la forme le fait que P, proche d'une complétive. Il accepte deux constructions transformationnelles, qui sont [extrap] et Ppv =: y :

```
ID=V_33_130; status=completed
lexical-info=[cat="verb",
              verb=[lemma="rendre",ppvse="true",
              aux-list=(etre="true"),prepositions=(),locatifs=()]]
args=(const=[pos="0",
             dist=(comp=[cat="NP",hum="true",
                         introd-prep=(),introd-loc=(),
                         origin=(orig="NO =: Nhum")])],
      const=[pos="1",
             dist=(comp=[cat="NP",hum="true",
                          introd-prep=(),introd-loc=(),
                         origin=(orig="N1 =: Nhum")]
                   comp=[cat="NP",nothum="true",
                         introd-prep=(),introd-loc=(),
                         origin=(orig="N1 =: N-hum")]
                   comp=[cat="leFaitComp",
                         introd-prep=(),introd-loc=(),
                         origin=(orig="N1 =: le fait Qu P")])])
```

<sup>8.</sup> La section 9.3 contient un autre extrait du lexique LGLex pour les entrées verbales croupir, croustiller et croûter de la table 31R.

Voici un exemple du lexique LGLex pour l'entrée nominale canular de la table FNAN des noms prédicatifs (cf. Fig. 3.4). La construction de base est N0 faire Det N à N1 et l'argument N1 est effaçable. Les arguments N0 et N1 doivent être des groupes nominaux humains. Il accepte les deux constructions N0 faire le N de V0-inf W et N0hum faire Det N à N1hum sur ce point :

```
ID=N_fnan_29; status=completed
lexical-info=[cat="noun",
              Vsup=[cat="verb",list=(value="faire")],
              noun=[notperm=[complete="canular"],noun1="canular"],
              detN=[list-det-modif=(det-modif=[det="un+une", modif="false"],
                                     det-modif=[det="un+une",modif="true"],
                                     det-modif=[det="des",modif="false"],
                                     det-modif=[det="<E>",modif="false"])],
              prepositions=()]
args=(const=[pos="0",
             dist=(comp=[cat="NP",hum="true"])],
      const=[pos="1",
             dist=(comp=[cat="NP",hum="true"])])
all-constructions=[absolute=(construction="true::NO faire Det N à N1",
                             construction="true::NO faire Det N",
                             construction="o::NO faire le N de VO-inf W",
                             construction="o::NOhum faire Det N à N1hum
                                                           sur ce point"),
                   relative=(),
                   verbales=(),
                   reductionsGN=()]
example=[example=]
```

Voyons à présent un exemple du lexique *LGLex* pour l'entrée figée avoir sur le cœur de la table C6 des expressions figées (cf. Fig. 3.5). Chacun des mots de l'entrée figée est découpé selon sa catégorie (verbe, préposition du deuxième argument Prép2, déterminant du deuxième argument Det2, nom figé C2 faisant également partie du deuxième argument) et le champ complete contient l'expression complète. La construction de base est N0 V N1 Prép2 Det2 C2, ce qui signifie que l'argument N1 est libre. L'argument N0 doit être un groupe nominal humain, alors que l'argument N1 peut être humain, non humain, une complétive à l'indicatif ou subjonctif. Il accepte la propriété transformationnelle Qu Pind = Aux V0-inf W, qui signifie que la complétive objet direct à l'indicatif, lorsque son sujet est coréférent au sujet de la principale et qu'elle contient un auxiliaire ou certains verbes (Gross, 1975) (p. 76), peut être remplacée par une infinitive non prépositionnelle dont le sujet implicite est coréférent au sujet de la principale :

```
ID=C_c6_210; status=completed
```

```
lexical-info=[cat="expr",
              exprF=[expr=[notperm=[complete="<E> avoir sur le coeur"],
                           verb="avoir",
                           prep2="sur"
                           det2="le",
                           c2="coeur"]]]
args=(const=[pos="0",
             dist=(comp=[cat="NP",hum="true",
                         introd-prep=(),introd-loc=(),
                         origin=(NO =: Nhum)])],
      const=[pos="1",
             dist=(comp=[cat="comp",mood="subj",
                         introd-prep=(),introd-loc=(),
                         origin=(NO =: Qu Psubj)],
                   comp=[cat="leFaitComp",
                         introd-prep=(),introd-loc=(),
                         origin=(NO =: le fait Qu P)],
                   comp=[cat="NP",nothum="true",
                         introd-prep=(),introd-loc=(),
                         origin=(NO =: N-hum)],
                   comp=[cat="NP",hum="true",
                         introd-prep=(),introd-loc=(),
                         origin=(NO =: Nhum)],
                   comp=[cat="comp",mood="ind",
                         introd-prep=(),introd-loc=(),
                         origin=(NO =: Qu Pind)])])
all-constructions=[absolute=("true::NO V N1 Prép2 Det2 C2"),
                   relative=(construction="Qu Psubj = de VO-inf W",
                             construction="Qu P = ceci",
                             construction="Qu P = Ppv")]
```

Enfin, voici un exemple du lexique *LGLex* pour l'entrée adverbiale *de visu* de la table PC des adverbes (cf. Fig. 3.6). Comme il s'agit d'un adverbe (semi-)figé, de même que pour les expressions figées, chacun des mots de l'entrée figée est découpé selon sa catégorie (préposition Prép, nom figé C). Sa structure de base est Prép C, accepte les trois constructions définitoires N0 V Adv W, Adv, N0 ne V pas W et Adv, N0 V W, et le sujet doit être humain :

```
relative=()]
```

Un travail en cours est d'inclure les propriétés de paraphrases, comme vu en 6.5.1 (à Adv parler, P ou N0 V W de (façon+manière) Adj), en tant que variantes des entrées adverbiales dans le lexique LGLex, mais également les propriétés de structures, comme vu en 6.5.3 (Prép1 Det1 C1, la structure de base étant Prép1 Det1 C1 Prép2 Det2 C2), et les propriétés d'intensification (plus Adv).

Nous projetons donc d'ajouter les champs suivants dans **lexical-info** contenant ces variantes :

- **paraphrases** (par exemple, à franchement parler pour l'adverbe franchement et de (manière+façon) sincère pour l'adverbe sincèrement);
- autres-structures (par exemple, jusqu'à la fin pour l'adverbe jusqu'à la fin des temps);
- **autres-ID**, désignant les autres entrées avec intensification (par exemple, *plus particulièrement* pour l'adverbe *particulièrement*).

L'exemple suivant montre un exemple du lexique  $LGLex^9$  pour l'entrée adverbiale jusqu'à la fin des (=de les) temps de la table PCDC des adverbes. On peut y voir le nouvel adverbe jusqu'à la fin, qui est ajouté dans **lexical-info** en tant qu'autre structure, suivi par sa structure morpho-syntaxique interne Prép1 Det1 C1, qui est ajoutée dans all-constructions :

```
ID=P_pcdc_270; status=completed
lexical-info=[cat="adv",
              exprF=[adv=[notperm=[complete="jusqu'à la fin de les temps"],
                     prep1="jusqu'à",
                     det1="la",
                     c1="fin",
                     prep2="de",
                     det2="les",
                     c2="temps"]]]
              paraphrases=(),
              autres-structures=(adv="jusqu'à la fin"]),
              autres-ID=()]
args=(const=[pos="0",
             dist=(comp=[cat="NP",nothum="true",
             introd-prep=(),introd-loc=(),
             origin=(NO =: N-hum)])])
all-constructions=[structureAdv=(construction="true::Prép1 Det1 C1 Prép2 Det2 C2",
                                 construction="o::Prép1 Det1 C1"),
                   absolute=(construction="true::NO V Adv W",
                             construction="true::Adv, NO V W",
                             construction="true::Adv, NO ne V pas W"),
                   relative=()]
```

<sup>9.</sup> Signalons que le codage des paraphrases (notamment, le codage des propriétés lexicales associées) n'étant pas terminé, ces champs n'apparaissent pas dans la version 3.3, mais seront inclus dans la suivante (Tolone et Voyatzi, 2011).

#### **7.4** Le script de *LGExtract*

Nous commençons par introduire quelques notations complémentaires (7.4.1), avant de montrer quelques extraits des scripts (7.4.2) illustrant le traitement des différents types de propriétés.

#### 7.4.1 Notations complémentaires

Les objets peuvent être paramétrés de deux façons : soit avec la notation @...@, comme vu dans la section 7.2, soit avec la notation @\*...@, permettant de récupérer la valeur dans la table des classes et non dans la classe elle-même. Cette deuxième notation n'est utilisée que pour les constructions, afin de permettre de distinguer les propriétés définitoires codées dans la table des classes des propriétés codées dans les classes. Dans le premier cas, le codage dans la table des classes est une valeur booléenne, alors que dans le deuxième cas, le codage est la valeur o. Cette information est nécessaire lors de la conversion au format Lefff, comme nous le verrons en 8.1.1. Par exemple, le code cidessous indique, pour la construction N0 V N1 (respectivement, N0 V N1 sur ce point), la valeur booléenne ou o dans la table des classes, suivie de ::, puis de la propriété N0 V N1 (respectivement, N0 V N1 sur ce point).

La propriété N0 V N1 est toujours vraie pour la classe 32H (codage + dans la table des classes) : @\*N0 V N1@ est remplacé par true. En revanche, la propriété N0 V Nhum sur ce point dépend des entrées et est codée o dans la table des classes pour la classe 32H et + dans la classe pour l'entrée alarmer : @\*N0 V Nhum sur ce point@ est remplacé par o. Les deux objets paramétrés montrés ci-dessus, qui seront ajoutés pour cette entrée, deviennent alors :

```
define abs NOVN1 {construction="true::NO V N1"};
define abs NOVNhumsurcepoint {construction="o::NO V Nhum sur ce point"};
```

Comme nous l'avons indiqué dans la section 7.2, l'instruction **prop** suivie d'un objet paramétré (notation @...@) permet d'indiquer des opérations qui sont appliquées uniquement si la propriété concernée est vraie. Il est possible également de tenir compte d'une propriété fausse (notation **not**@...@), mais avec la contrainte que la colonne doit obligatoirement être codées pour toutes les tables. Par exemple, dans les classes de noms composés, l'entrée est composée de plusieurs mots où il est nécessaire d'indiquer l'ordre dans le script. Cependant, l'ordre dépend de la colonne Adj permut obl (codée dans les tables FNA, FNANA et FNPNA), ce qui oblige l'adjectif à se placer avant le nom si la colonne est codée +. Au total, il y a quatre structures possibles dans toutes les tables de noms :

```
<ENT>N
<ENT>N <ENT>Adj
<ENT>N <ENT>Prép <ENT>Detc <ENT>Nc
```

```
<ENT>Adj <ENT>N
```

Les trois premières ne posent aucun problème car elles ne se chevauchent pas, en revanche la dernière doit être un cas à part, qui correspond justement au codage + de la colonne Adj permut obl. Le code suivant indique les deux possibilités pour extraire l'entrée complète du nom composé, puis le traitement adéquat selon si la colonne Adj permut obl est codée + ou -:

#### 7.4.2 Extrait des scripts

Comme nous l'avons expliqué dans la section 7.2, pour chaque catégorie, nous avons un script indiquant les opérations à faire pour chaque propriété. On peut distinguer différents types de propriétés qui sont traités différemment <sup>10</sup>:

- les propriétés concernant l'entrée ou les mots dérivés avec les champs lexicaux associés (par exemple, <ENT>V et <ENT>V-adj), les auxiliaires utilisés pour conjuguer les verbes aux temps composés (Aux =: avoir et Aux =: être), ainsi que les clitiques figés avec le verbe (par exemple, Ppv =: se figé) 11 :

```
prop @<ENT>V@{
    create predV;
    create args;
    add prepositions in predV;
    add locatifs in predV;
    create all-constructions;
    add absolute in all-constructions;
    add relative in all-constructions;
    create example;
}
prop @V-adj@{
    add v-adj in predV;
}
```

```
define lexical-info predV [cat="verb",verb=[lemma="@<ENT>V@"], aux-list=()];
```

<sup>10.</sup> Les exemples suivants sont tirés des verbes uniquement, les particularités des autres catégories étant détaillées par la suite.

<sup>11.</sup> Comme déjà vu dans la section 7.2, le code définissant le prédicat verbal  $\mathbf{predV}$ , en l'ajoutant dans  $\mathbf{lexical\text{-info}}$  est :

```
prop @Aux =: avoir@{
   add avoir in predV.aux-list;
}
prop @Ppv =: se figé@{
   add ppvse in predV.verb;
}
```

- les constructions absolues ou complètes qui peuvent être aussi bien la structure de base N0 V N1, que la construction N0 V N1 de N2 codant un argument supplémentaire, ou encore la construction N0 V codant l'effacement d'un argument. Chaque construction est indiquée dans son ensemble, sans faire référence à un argument sous-entendu. On y inclut également les transformations complètes telles que N1 être Vpp par N0, qui, de la même manière, se suffisent à elle-même pour savoir de quels arguments elles sont constituées :

```
prop @NO V N1@{
   add NOVN1 in absolute;
}
prop @N1 être Vpp par NO@{
   add N1etreVppparNO in absolute;
}
```

Notons également que pour certaines constructions, telles que N0 V Prép N1, le programme crée une liste vide de prépositions pour une position donnée (ici, 1, ce qui correspond aux prépositions précédant l'argument N1)  $^{12}$ :

```
prop @NO V Prép N1@{
  add preposition1 in prepositions;
  add NOavoirDetNPrepN1 in absolute;
}
```

- les constructions relatives, incluant la pronominalisation (qui remplace un argument par Ppv, comme par exemple dans à N1 = Ppv =: le), les compléments supplémentaires indiqués sans rappeler la construction de base (par exemple, par N4) et les transformations relatives, dont toute la construction n'est pas indiquée. Cela est possible, soit par la présence d'un W désignant d'autres arguments sous-entendus (par exemple, N0 être Vpp W), soit par un code indiquant une transformation spécifique (par exemple, [passif par], qui sous-entend N1 V par N0 ou N1 V par N0 dans N2, etc. en fonction des autres arguments existants puisque tous les arguments sont conservés):

```
prop @a N1 = Ppv =: le@{
   add aN1Ppvle in relative;
}
prop @par N4@{
   add parN4 in relative;
}
prop @NO être Vpp W@{
   add NOetreVppW in relative;
}
```

<sup>12.</sup> Le code associé à **preposition1** est le suivant : define preposition preposition1 [id="1",list=()];

```
prop @[passif par]@{
     add passifpar in relative;
- la distribution des arguments (par exemple, N0 =: Nhum et N0 =: Qu P) ou leur
  différentes interprétations, spécifiant le rôle thématique (par exemple, N1 source), où
  l'on distingue chaque argument (1, 2, 3, etc.) et chaque distribution (trait sémantique
  humain, complétive, infinitive, etc.) 13:
   prop @NO =: Nhum@{
     add NO in args;
     add NOhum in NO.dist;
     add orig-NONhum in NOhum.origin;
   prop @NO =: Qu P@{
     add NO in args;
     add completive in NO.dist;
     add completiveSubj in NO.dist;
     add orig-NOQuP in completive.origin;
     add orig-NOQuP in completiveSubj.origin;
   prop @N1 source@{
     add N1 in args;
     add src in N1hum;
     add src in N1-hum;
     add orig-N1source in N1hum.origin;
     add orig-N1source in N1-hum.origin;
- la distribution des prépositions (par exemple, Prép1 =: à), où l'on distingue chaque
  argument (1, 2, 3, etc.) et chaque préposition :
   prop @Prép1 =: a@{
     add a in preposition1.list;
- la distribution des prépositions locatives (par exemple, Loc N1 =: à N1), où l'on dis-
  tingue chaque argument (1, 2, 3, etc.) et chaque préposition :
   prop @Loc N1 =: à N1@{
     add a in locatif1.list;
   }
```

Parfois certains types se recoupent. C'est le cas d'une distribution de préposition locative associée à une interprétation de l'argument, spécifiant le rôle thématique (par exemple, Loc N1 =: à N1 destination), ou d'une distribution d'argument associée à une distribution de préposition (par exemple, N1 =: de V0-inf W) :

```
prop @Loc N1 =: à N1 destination@{
  add N1 in args;
```

<sup>13.</sup> Dans le champs **origin** figurent le ou les intitulés qui sont à l'origine de cette distribution, pour garder un lien direct avec les tables, uniquement à titre informatif.

```
add destNP in N1.dist;
   add a in destNP.introd-loc;
   add orig-LocN1aN1destination in destNP.origin;
}
prop @N1 =: de VO-inf W@{
   add N1 in args;
   add inf0 in N1.dist:
   add de in inf0.introd-prep;
   add orig-N1deVO-infW in infO.origin;
}
  Pour les noms, les mêmes types de propriétés existent avec quelques différences :
 - l'entrée pouvant être composée de plusieurs mots, plusieurs propriétés concernes
    uniquement les mots de l'entrée (<ENT>N, <ENT>Adj, <ENT>Prép, <ENT>Detc,
    <ENT>Nc), elles sont ajoutées dans detN.noun inclus dans predN<sup>14</sup>:
     prop @<ENT>N@{
       create predN;
       add detN in predN;
       add noun1 in detN.noun;
       add Vsup in predN;
       add verbales in all-constructions;
       add reductionsGN in all-constructions;
     }
     prop @<ENT>Adj@{
       add adj1 in detN.noun;
  - les constructions sont obligatoirement avec un verbe support (par exemple,
    N0 avoir Det N Prép N1), qui est ajouté à la liste associée à Vsup 15, inclus
    précédemment dans predN (cf. <ENT>N) :
     prop @NO avoir Det N Prép N1@{
       add avoir in Vsup.list;
       add preposition1 in prepositions;
       add NOavoirDetNPrepN1 in absolute;
  - les constructions verbales, incluses précédemment dans all-constructions (cf.
    <ENT>N), sont traités séparément (par exemple, N0 V N1) :
     prop @NO V N1@{
       add NOVN1 in verbales;
 14. Le code de \mathbf{predN} et \mathbf{detN} est :
define lexical-info predN [cat="noun"];
define detN detN [noun=[],list-det-modif=()];
 15. Le code de Vsup et de avoir est :
define Vsup Vsup [cat="verb",list=()];
define Vsuplex avoir value="avoir";
```

```
- parmi les distributions, nous avons également celles des verbes supports (par
  exemple, Vsup =: (émettre+formuler)) :
   prop @Vsup =: (émettre+formuler)@{
     add emettre in Vsup.list;
     add formuler in Vsup.list;
   }
- parmi les distributions, nous avons également celles du déterminant précédant le
  nom prédicatif (par exemple, Det =: le), qui est ajouté à la liste associée à detN<sup>16</sup>,
  inclus précédemment dans predN (cf. <ENT>N) :
   prop @Det =: le@{
     add le in detN.list-det-modif;
   }
- nous avons de plus les propriétés de réduction du groupe nominal (par exemple,
  GN =: le N de N0), incluses précédemment dans all-constructions (cf. <ENT>N):
   prop @GN =: le N de NO@{
     add leNdeNO in reductionsGN;
```

Pour les expressions figées, il n'y a pas de type différent. On peut cependant remarquer que l'entrée étant composée de plusieurs mots, le nombre de propriétés concernées est encore plus important que pour les noms prédicatifs.

Pour les adverbes, nous avons de plus la structure de l'adverbe (par exemple, Prép1 Det1 C1) :

```
prop @Prép1 Det1 C1@{
   add Prep1Det1C1 in structureAdv;
}
```

#### 7.5 Discussion

Nous effectuons un bilan sur notre outil LGExtract (7.5.1), avant de conclure (7.5.2).

#### 7.5.1 Avantages et inconvénients de LGExtract

La construction du lexique LGLex nous a permis d'identifier clairement les avantages et inconvénients de notre outil. Son avantage principal est l'utilisation de la table des classes. En pratique, toute l'information manquante est rassemblée dans un seul fichier et non dans autant de fichiers que de classes, comme dans l'approche de Gardent et al. (2006). De plus, il apporte une vision linguistique plus globale : auparavant, la méthode pour générer un lexique syntaxique à partir des tables du Lexique-Grammaire était de trouver les propriétés définitoires de chaque classe et de les rendre explicites. Maintenant, avec la table des classes, on peut chercher si une propriété donnée est intéressante pour

```
16. Le code de detN (comme vu précédemment) et de le est : define detN detN [noun=[],list-det-modif=()]; define det-modif le [det="le+la+l",modif="false"];
```

une classe donnée, et cela pour l'ensemble des propriétés de toutes les classes de la catégorie concernée. Ceci fait apparaître de nouvelles questions linguistiques dans le cadre des tables du Lexique-Grammaire.

De plus, la combinaison de *LGExtract* avec la table des classes simplifie la maintenance du lexique syntaxique. D'abord, toutes les opérations de chaque propriété sont encodées une seule fois dans le script, indépendamment de chaque classe. Ensuite, s'il survient qu'une nouvelle propriété est constante sur toute une classe, il faut simplement ajouter un symbole + dans la case correspondante de la table des classes. Le script n'a pas besoin d'être modifié pour ajouter cette information dans le lexique généré, étant donné que toutes les opérations concernant cette propriété ont déjà été codées.

Le système nécessite que chaque propriété possède exactement une signification dans toutes les classes. L'emploi de cet outil nous a permis de garder la table des classes cohérente. C'est ainsi qu'auparavant, la propriété zone était une zone de texte dans plusieurs classes mais avec des interprétation différentes :

- dans la plupart des tables, elle fournissait la valeur lexicale des prépositions introduisant les compléments verbaux indépendamment de leur position dans la construction canonique (que nous avons renommée Prép1, Prép2 ou Prép3 selon les cas);
- dans la table 38L0, elle indiquait le suffixe à ajouter au verbe afin d'obtenir son nom dérivé (renommée suffixeN);
- dans les tables 32R3 et 35R, elle donnait un exemple de complément (renommée thèmeN1).

Nous avons dû ajouter de nouvelles propriétés afin qu'il y en ait une par sens. En particulier, les prépositions ont été numérotées pour qu'il soit possible d'identifier directement les compléments qu'elles introduisent.

Toutefois, certaines limitations sont clairement apparues. Il est parfois nécessaire de répéter des dizaines d'opérations similaires sur des ensembles de propriétés. Par exemple, il est nécessaire de créer manuellement pour chaque propriété des objets linguistiques différents seulement par leur numérotation. Cela est dû au fait que le script ne permet pas de faire des boucles, des fonctions avec paramètres, des tableaux et de la création dynamique d'objets linguistiques. De plus, le programme n'est pas capable d'effectuer des opérations dans un ordre requis. Par exemple, dans les classes dont l'entrée comporte plusieurs mots, comme les classes de noms composés, d'expressions figées ou d'adverbes (semi-)figés, les différents composants de l'entrée sont codés dans plusieurs colonnes successives selon leur ordre d'apparition. Mais il est impossible d'obtenir le nom complet sans en indiquer l'ordre dans le script lui-même (cf. section 7.2). Il serait donc intéressant d'implémenter des macros permettant de telles opérations.

#### 7.5.2 Conclusion

Nous avons développé un outil pour générer des lexiques syntaxiques pour le TAL à partir des tables du Lexique-Grammaire nommé *LGExtract*. Une table des classes est utilisée pour fournir les informations manquantes dans les classes : cela rend explicite toutes les informations implicites sous-jacentes à ces classes. Un script d'extraction par catégorie associe à chaque propriété un ensemble d'opérations qui est activé pour

#### Chapitre 7 Conversion au format LGLex

chaque entrée lorsque la propriété est vraie. Appliqué aux tables du Lexique-Grammaire du français de toutes les catégories (verbes distributionnels, noms prédicatifs, expressions figées et adverbes), cet outil produit un lexique syntaxique exploitable dans les applications de TAL, telles que l'analyse syntaxique.

C'est à partir des entrées de la version textuelle du lexique LGLex que nous avons effectué une conversion vers le format Alexina, c'est-à-dire le format du lexique syntaxique Lefff, pour permettre son intégration dans l'analyseur syntaxique FRMG.

# 8

### Conversion au format Lefff

La création du lexique *LGLex* nous a permis d'envisager l'utilisation des tables du Lexique-Grammaire dans un analyseur syntaxique à grande échelle, l'analyseur FRMG (Thomasset et de La Clergerie, 2005). L'exploitation de l'ensemble des informations lexicales représentées dans les tables du Lexique-Grammaire dans le contexte d'un analyseur syntaxique nécessite de répondre à trois défis :

- représentation entièrement formalisée de ces informations lexicales;
- couplage avec un analyseur syntaxique;
- évaluation comparative avec d'autres ressources lexicales, à la fois au niveau des entrées et au niveau des performances de l'analyseur.

Ce chapitre et les suivants décrivent la façon dont nous avons répondu à ces défis, en commençant tout d'abord par la conversion des verbes et des noms prédicatifs du lexique LGLex au format Lefff (cf. section 4.1), comme nous l'avons décrit dans Sagot et Tolone (2009b); Tolone et Sagot (2011). La section 8.1 présente les fondements linguistiques et la méthodologie pratique de la conversion de LGLex au format Lefff, en terminant par les problèmes que posent la conversion des expressions figées. Enfin, la section 8.2 présente le lexique obtenu.

## 8.1 Conversion du lexique LGLex en un lexique au format Alexina

Comme nous l'avons mentionné en 2.2.2, la plupart des lexiques syntaxiques ne contiennent que des entrées verbales, à l'exception des tables du Lexique-Grammaire et du Lefff, ce dernier étant dans un format TAL directement exploitable dans un analyseur syntaxique, ce qui n'est pas le cas des tables. Le format Lefff est donc le plus adapté. C'est pourquoi nous avons réalisé la conversion des tables des verbes simples

et des noms prédicatifs au format Lefff à partir du lexique LGLex. Le même travail est également en cours pour les tables d'expressions figées (voir 8.1.6)  $^1$ . Le script écrit en Perl effectuant cette conversion se nomme LGLex2ilex et fait partie de la distribution actuelle du Lefff $^2$ .

La conversion se fait en quatre étapes : identification de la construction de base et de ses variantes (8.1.1), construction des cadres de sous-catégorisation au format Lefff (8.1.2), construction des listes de redistributions associées à chaque entrée (8.1.3), ajout aux entrées des informations complémentaires (8.1.4), que nous illustrons par des exemples d'entrées complètes (8.1.5). Enfin, nous détaillons le travail amorcé pour les expressions figées (8.1.6).

### 8.1.1 Découpage en entrées : la construction de base et ses variantes

Une entrée donnée dans le lexique LGLex est associée à diverses constructions. Parmi celles-ci, on peut distinguer plusieurs types de constructions :

- 1. la construction de base choisie comme référence pour le calcul des autres;
- 2. les constructions de base étendues, obtenues par adjonction d'arguments à la construction de base. Une grande partie des constructions sont des intermédiaires entre la construction de base et une construction dite de base maximalement étendue ou CBME. Par exemple, l'entrée de rassembler dans la table 32PL (Max a rassemblé ses articles (E+dans un ouvrage)) a pour construction de base la construction transitive simple N0 V N1, mais la possibilité d'ajouter un complément en Loc N2 conduit à une CBME de la forme N0 V N1 Loc N2;
- 3. les constructions qui sont des variantes de la construction de base, obtenues par effacement d'un ou de plusieurs arguments, ou par changement de type de réalisation (Qu P devenant V0-inf W, par exemple);
- 4. les constructions qui sont en réalité des redistributions (constructions relatives telles que [passif de], constructions absolues de type N1 est Vpp de ce Qu P, cf. section 7.3).
- 5. les constructions qui ne sont pas des variantes de la CBME mais qui ne sont pas considérées comme des redistributions dans le format Lefff. Par exemple, dans la table 9, la CBME est N0 V N1 à N2 de Nhum pour certaines entrées. Le complément des constructions N0 V après Nhum et N0 V contre Nhum est incompatible avec les compléments de la CBME :

Paul écrit à Marie de Luc qu'il est génial

<sup>1.</sup> Notons que la conversion des adverbes au format Lefff n'a pas été envisagée pour le moment, car le Lefff contient déjà la liste de tous les adverbes présents dans les tables (sans prendre en compte les variantes, cf. section 7.3 avec pour exemple l'entrée jusqu'à la fin des temps) et que FRMG ne fait que les intégrer à tous les endroits possibles dans une phrase sans tenir compte de leur construction syntaxique.

<sup>2.</sup> Notons qu'il est également disponible sur le site http://infolingu.univ-mlv.fr/ (Données Linguistiques > Lexique-Grammaire > Téléchargement).

Luc écrit contre Bush \*Luc écrit contre Bush à Marie de Luc qu'il est génial

De par leur origine, les informations présentes dans la section  $\operatorname{args}$  d'une entrée LGLex participent à la définition de constructions qui sont des variantes de la construction de base, étendue ou non (cas 2 et 3). Pour identifier les entrées au format  $\operatorname{Lefff}$  à créer à partir d'une entrée  $\operatorname{LGLex}$ , il faut donc identifier, parmi les constructions listées dans la section  $\operatorname{all-constructions}$  la construction de base maximalement étendue (CBME).

Pour identifier la CBME, nous avons développé une méthode pour *aligner* deux constructions, c'est-à-dire construire des correspondances entre arguments, malgré leurs différences de surface (par exemple, Qu P et N1, ou encore à N1 et Prép N1 si l'on sait par ailleurs, grâce à la section **lexical-info** ou à la distribution concernée, que la Prép peut être à) et leur possible effacement. Les extensions de la construction de base sont alors identifiées comme étant celles qui s'alignent avec la construction de base ³, à l'exception d'un ou plusieurs arguments supplémentaires. La CBME est alors la construction obtenue en rajoutant à la construction de base l'ensemble des arguments supplémentaires possibles <sup>4</sup>.

Nous identifions alors les variantes de cette CBME à l'aide de ce même algorithme d'alignement <sup>5</sup>. Pour chaque variante, nous construisons une séquence d'opérations élémentaires permettant de la reconstituer à partir de la CBME. Ces opérations permettront de construire, pour chaque argument, la liste de ses réalisations possibles, et de déterminer si elles sont effaçables ou non.

À titre d'exemple, voici au format LGLex l'entrée du verbe ruisseler de la table 35L :

<sup>3.</sup> La construction de base fait partie des propriétés précédées de la mention **true**:: dans la sous-section **absolute** du lexique *LGLex* (cf. section 7.3). S'il y en a plusieurs, on prend la première apparaissant dans le lexique.

<sup>4.</sup> La situation est en réalité plus complexe. En effet, certains de ces arguments supplémentaires ne prennent part à aucune des constructions, et ne sont connus que grâce à leur description dans la section **args** de l'entrée. Elles sont prises en compte correctement par notre processus.

<sup>5.</sup> À l'exception de certaines constructions relatives, telles que Ppv =: y, pour lesquelles la description de la variante correspondante est obtenue directement.

La construction de base est donc N0 V Loc N1 (cas 1). Les indications sémantiques de type source et destination étant ignorées, la construction N0 V Loc N1 source Loc N2 destination en est l'unique extension, il s'agit donc de la CBME (cas 2). La construction de base devient une variante de la CBME, par effacement de l'argument 2. La construction N0 V est également identifiée comme une variante de la CBME, par double effacement (cas 3). La construction N0 être V-ant est laissée de côté pour l'instant. Du côté des constructions relatives, on trouve la construction Ppv =: y (respectivement, Ppv =: en) qui permettra d'ajouter y (respectivement, en) à la liste des réalisations de l'argument locatif (respectivement, délocatif) (cas 3). Enfin, la construction [extrap] induira l'adjonction d'une redistribution impersonnelle (%actif\_impersonnel) à l'entrée (cas 4).

Les constructions qui relèvent du cas 5 reçoivent un traitement par défaut, qui peut être de deux types :

- si l'on veut préserver au mieux le découpage original en entrées, ces constructions donnent lieu à la création de redistributions (au sens du Lefff) ad hoc qui ne sont pas définies formellement;
- si l'on veut préserver l'utilisabilité dans les outils automatiques (compilation à la Lefff puis utilisation dans un analyseur syntaxique), ces constructions donnent lieu à la création d'entrées distinctes, dites *entrées secondaires* (voir l'option -nuc expliquée dans l'annexe D).

Notons que les entrées secondaires crées ont le même identifiant. Le découpage original peut donc être retrouvé, en associant à chaque identifiant (et non entrée) l'ensemble des constructions.

Pour certaines constructions, il semble qu'elles auraient dû conduire à créer des entrées secondaires avec un nouvel identifiant car leur sens est différent. Par exemple, dans la table 13, la construction de base est  $N0\ V\ N1\ de\ N2$  et certaines entrées acceptent la transformation  $N1\ se\ V$  de ce  $Qu\ P$ :

```
Max félicite Luc qu'il ait réussi à séduire Léa
Luc se félicite d'avoir réussi à séduire Léa (se féliciter = se réjouir)
```

Mais par exemple, pour l'entrée *instruire*, le sens reste le même :

Jo a instruit Luc de ce qui s'est passé

Luc s'est instruit de ce qui s'est passé

Cela montre qu'il n'y a pas besoin de créer d'entrée secondaire avec un identifiant différent, mais plutôt qu'il faudrait retirer des tables les codages + qui ne respectent pas le principe d'avoir «un sens par entrée».

#### 8.1.2 Construction des cadres de sous-catégorisation

Une fois répertoriées les entrées à produire, les cadres de sous-catégorisation sont construits. Pour cela, on construit d'abord le cadre correspondant à la construction maximale de chaque entrée (la CBME pour l'entrée canonique, ou l'unique construction des entrées secondaires). Pour cela, on utilise des heuristiques permettant de définir la fonction syntaxique de chaque argument, ainsi que sa réalisation canonique.

Les fonctions syntaxiques sont obtenues de la façon suivante. Tout d'abord, le premier argument reçoit toujours la fonction  $Suj^6$ . Le premier argument post-verbal, s'il est direct, se voit attribuer la fonction Obj, sauf pour les entrées de la table 32NM <sup>7</sup>. Ensuite, un argument introduit par à (respectivement, de) reçoit la fonction syntaxique Objà (respectivement, Objde), sauf si un indice complémentaire vient contredire ce choix <sup>8</sup>. Les arguments introduits par Loc ont la fonction syntaxique Loc, sauf ceux de la forme Loc Ni source ou vérifiant Loc Ni =: de Ni source, qui ont la fonction syntaxique Dloc. Enfin, les autres arguments sont considérés comme des Att s'ils sont directs, et comme des Obl s'ils sont introduits par une préposition (Obl2 si un Obl existe déjà).

Pour les noms prédicatifs, le même ensemble de fonctions est utilisé, mais le verbe est remplacé par un verbe support suivi d'un groupe nominal n'ayant pas de fonction syntaxique.

Les réalisations de ces fonctions sont construites en deux temps. Tout d'abord, le type de syntagme (nominal, infinitif, phrastique, etc.) est déterminé. La réalisation scompl correspond aux distributions de catégorie comp et ceComp ainsi qu'aux arguments dans les constructions en Qu P. La réalisation sinf correspond aux distributions de catégorie inf et aux arguments en Vi-inf W. La réalisation qcompl correspond aux distributions de catégorie siPOuSiP. La réalisation sn correspond aux distributions de catégorie NP et leFaitComp et aux arguments en Ni. Enfin, la réalisation sa correspond aux distributions de catégorie adj. De plus, la réalisation cln (clitique nominatif) est ajoutée systématiquement à la fonction syntaxique Suj.

Ceci accompli, il reste à lister les introducteurs possibles. L'ensemble des prépositions et autres introducteurs (par exemple, et) sont pris en compte. En particulier, la

<sup>6.</sup> Les constructions impersonnelles sont toutes obtenues sous forme de redistributions, puisque la table 31I ne fait plus partie des entrées verbales du lexique *LGLex*.

<sup>7.</sup> Cette table rassemble les verbes à pseudo-objet de type peser (Le sac pèse 10 kg) ou sentir (Cette pièce sent la fumée).

<sup>8.</sup> Par exemple, pour un argument N1 introduit par à, la propriété à N1 = Ppv =: le lui conférera la fonction syntaxique Obj (comme dans Il apprend à conduire / Il l'apprend), alors que la propriété à N1 =: y lui conférera la fonction syntaxique Loc.

préposition est parfois Prép. Il faut alors extraire la liste des prépositions possibles de la section lexical-info de l'entrée LGLex (dans le champ **prepositions**) et/ou dans la distribution concernée (dans le champ **introd-prep**). Lorsque la préposition est Loc, elle peut être précisée par les mêmes moyens que Prép (quoique dans des champs distincts : locatifs et introd-loc), mais ce n'est pas obligatoire (toute préposition locative étant alors admise).

Le résultat de ces heuristiques est le cadre de sous-catégorisation au format Lefff pour la construction maximale de l'entrée. Ainsi, la CBME de l'exemple précédent devient :

```
<Suj:sn|cln,Dloc:sn,Loc:sn>
```

Les constructions maximales des entrées qui sont canoniques (leur construction maximale est une CBME) doivent alors être complétées. Pour cela, nous ajoutons tout d'abord les réalisations issues de constructions telles que Loc N1 = Ppv =: y. On peut avoir cln pour le clitique nominatif, cla pour le clitique accusatif, cld pour le clitique datif, y pour le clitique locatif, en pour le clitique génitif.

Nous répercutons ensuite pour chaque variante de la CBME la séquence d'opérations élémentaires permettant de les dériver de la CBME de la façon suivante : tout effacement d'un argument rend l'argument facultatif; tout changement de réalisation induit une nouvelle réalisation possible de la fonction syntaxique concernée.

Les dépendances entre ces opérations (par exemple, tel argument est effaçable seulement si tel autre l'est aussi) sont perdues : tout effacement est considéré comme possible sans condition, alors même qu'il peut ne venir que d'une seule construction. De même, toute réalisation d'un argument autorisée par une construction devient possible quelles que soient les réalisations des autres arguments. Il s'agit là formellement d'une approximation des données linguistiques présentes dans les tables (et dans le lexique LGLex). Cette approximation a le mérite de permettre de diminuer au maximum le nombre d'entrées, même s'il reste à démontrer qu'elle n'a pas de conséquences pour l'utilisation du lexique produit, puisqu'en théorie les dépendances entre effacements permettent d'éliminer des analyses et donc de lever des ambiguïtés. Cette approximation est également adoptée par le modèle de la valence mis en œuvre par le lexique DICOVALENCE (van den Eynde et Mertens, 2006).

Le résultat de ce processus est un cadre de sous-catégorisation, avec alternatives et arguments optionnels. Le cadre construit pour l'entrée canonique de l'exemple précédent est alors :

```
<Suj:cln|sn,Dloc:(de-sn|de_chez-sn|en),Loc:(vers-sn|dans-sn|y)>
```

#### 8.1.3 Identification des redistributions admissibles

Le cadre de sous-catégorisation de base construit à la section précédente est le cadre dit *profond*, car il relève de la syntaxe profonde. Néanmoins, pour les verbes, la table 31I des verbes impersonnels intrinsèques et autonomes faisant partie des expressions figées, ce cadre profond correspond toujours à un cadre de surface, celui de la (re)distribution

active (%actif). Toutes les entrées verbales se voient donc attribuer au moins cette (re)distribution.

Les autres redistributions admissibles sont identifiées parmi les constructions répertoriées dans la section **all-constructions** de l'entrée LGLex:

- [passif par] et [passif de] correspondent aux redistributions %passif (Jean assistait Max depuis des années → Max était assisté par Jean depuis des années) et %passif\_de (Marie aime Pierre → Pierre est aimé de Marie);
- [extrap] correspond à la redistribution %actif\_impersonnel, c'est-à-dire, constructions impersonnelles à l'actif avec le sujet inversé, le cas échéant (Un accident est arrivé à Jean → Il est arrivé un accident à Jean);
- il être Vpp Prép N1 (E + par N0) (anciennement [extrap][passif]) correspond à la redistribution %passif\_impersonnel, c'est-à-dire, constructions impersonnelles au passif avec le sujet inversé, le cas échéant (Cette nouvelle information clarifie pourquoi Max est fâché → Il est clarifié par cette nouvelle information pourquoi Max est fâche).

De plus, on a la redistribution %ppp\_employé\_comme\_adj pour les participes passés employés comme adjectifs ( $Marie\ s'assoie \rightarrow Marie\ est\ assise$ ), qui est appliquée par défaut à tous les Obj puisque l'information n'est pas codée dans les tables.

Comme cela a été étudié par Danlos et Sagot (2008), les redistributions pronominales (de type se moyennes et se neutres) étant mal codées dans le Lexique-Grammaire, nous ne les avons pas prises en compte en tant que redistributions.

Quant aux entrées nominales, on leur attribut uniquement la redistribution % default, qui construit un cadre de sous-catégoriation final identique à l'initial. De plus, elles peuvent avoir la redistribution % passif ( $Max\ fait\ une\ déposition\ contre\ Luc\ auprès\ du\ commissariat$ ).

Le résultat de cette extraction pour l'exemple précédent est ainsi :

```
<Suj:cln|sn,Dloc:(de-sn|de_chez-sn|en),Loc:(vers-sn|dans-sn|y)>;;%actif, %actif_impersonnel
```

Un exemple plus riche, tel que celui de l'entrée de *clouer* dans la table 36SL (*Max a cloué cette planche au mur*), devient quant à lui :

```
<Suj:cln|sn,Obj:sn,Loc:(avec-sn|et-sn|à-sn|sur-sn)>;;%actif,%passif,%ppp_employé_comme_adj
```

#### 8.1.4 Prise en compte des informations complémentaires

D'autres types d'informations sont alors ajoutés, pour former l'entrée finale. Tout d'abord, le prédicat sémantique correspondant à l'entrée, qui est le plus souvent *Lemma* (c'est-à-dire identique au lemme verbal), peut être complété en fonction d'informations présentes dans la section **lexical-info** de l'entrée *LGLex* (par exemple, **ppvse="true"**, **neg="true"**, etc. donne se *Lemma*, ne pas *Lemma*, etc.). Le lemme lui-même, en-tête de l'entrée, est extrait du champ **lemma**, et complété par le numéro de la table dont est

issue l'entrée, ainsi que du numéro d'entrée dans cette table. Ainsi, même lorsqu'une entrée LGLex donne lieu à plusieurs entrées au format Lefff, ces entrées partagent un même identifiant.

Les informations syntaxiques complémentaires les plus intéressantes sont représentées sous forme de macros. Il s'agit des informations suivantes :

- auxiliaire de conjugaison du verbe, récupéré dans le champ aux-list, qui induit l'ajout de la macro @avoir (par exemple, pour le verbe achever dans Max a achevé de peindre le mur) ou de la macro @être (par exemple, pour le verbe s'arrêter dans Max s'est arrêté de boire);
- caractère (essentiellement) pronominal du verbe : ppvse="true", macro @pron (par exemple, pour le verbe arrêter dans l'exemple précédent);
- caractère obligatoirement négatif du verbe : **neg="true"**, macro @neg (par exemple, pour le verbe *rajeunir* dans *Que sa fille ait 20 ans ne rajeunit pas Max*);
- autres clitiques obligatoirement figés au verbe : **ppven="true"**, macro @pseudo-en (par exemple, le verbe baver dans Max en bave avec Luc), **ppvy="true"**; macro @pseudo-y (par exemple, le verbe aller dans Luc y va); **ppvle="true"**, macro @pseudo-le (par exemple, le verbe disputer dans La haine le dispute à la colère); **ppvla="true"**, macro @pseudo-la (par exemple, le verbe fermer dans Fermez-la); **ppvles="true"**, macro @pseudo-les (par exemple, le verbe aligner dans Max les aligne à Luc);
- mode des complétives possibles (champ **mood** de la distribution correspondante), indiquée sous la forme de macros de type @fM, où f vaut respectivement SComp, Comp, AComp et DeComp pour les complétives de fonction syntaxique Suj, Obj, Objà et Objde, et où M est Ind ou Subj. Par exemple, @SCompInd indique que si le sujet est réalisé par un syntagme phrastique fini, son mode est l'indicatif (par exemple, qu'il fait beau dans Pierre dit qu'il fait beau); au contraire, @CompSubj indique que si l'objet direct est réalisé par un syntagme phrastique fini, son mode est le subjonctif (par exemple, qu'il fasse beau dans Pierre veut qu'il fasse beau);
- informations de contrôle, extraites du champ **contr** des distributions ou du nombre i dans les arguments de type Vi-inf au sein des constructions, et qui sont représentées par des macros de la forme  $@Ctrlf_1f_2$ , où  $f_1$  est la fonction syntaxique du contrôleur et  $f_2$  celle du contrôlé. Par exemple, @CtrlSujObj indique que s'il est réalisé par un syntagme infinitif, l'objet est contrôlé par le sujet (par exemple, *chercher du pain* est contrôlé par Pierre dans Pierre va chercher du pain).
- trait sémantique humain ou non humain pour le syntagme nominal (champ cat="NP" avec le champ hum="true" ou nothum="true" de la distribution correspondante), indiqué sous la forme de macros de type @fM, où f est la fonction syntaxique et M est Nhum ou N-hum. Par exemple, @ObjàNhum indique que l'objet indirect introduit par la préposition à peut dénoter une personne ou un animal linguistiquement assimilé à une personne lorsqu'il est réalisé par un syntagme nominal (par exemple, Vercingetorix s'est rendu à l'ennemi); au contraire, @ObjàN-hum indique que l'objet indirect introduit par la préposition à peut dénoter un non humain (par exemple, Jean s'est rendu à mon opinion); dans

ce cas, @ObjàNhum et @ObjàN-hum ne font pas partie de la même entrée car le sens de se rendre est différent; dans d'autres cas, par exemple, Max va tomber et Le verre va tomber, @SujNhum et @SujN-hum indiquent que le sujet peut dénoter un humain et un non humain pour la même entrée; si aucune indication n'est donné pour un argument, on peut considérer que les deux sont toujours possibles.

Ce dernier type de macros, n'existant pas dans le Lefff, il a été créé afin de représenter ce trait sémantique présent dans l'ensemble des tables. Les autres traits sémantiques, n'étant pas codés systématiquement, n'ont pas été gardés, mais l'on peut envisager d'ajouter d'autres macros si nécessaire.

Enfin, la table de conjugaison devant être associée à l'entrée est récupérée dans le Lefff, permettant ainsi la compilation du lexique obtenu avec la description morphologique du français du Lefff.

Pour les verbes, les différentes classes sont v-er:std pour les verbes du premier groupe, y compris certains verbes qui se terminent en eler et -eter (acheter : j'achète), v-er:dbl pour les verbes qui se terminent en eler et -eter qui doublent le l ou le t (jeter : je jette), v-ir2 pour les verbes du deuxième groupe (finir), v-ir3 pour les verbes réguliers du troisième groupe qui se terminent en -ir (servir), v-re3 pour les verbes réguliers du troisième groupe qui se terminent en -re (vendre, mordre, vaincre, ébattre, rompre), puis des classes spécifiques pour les verbes très irréguliers (par exemple, v67 pour les verbes qui se terminent en -paraître, v79 pour ceux qui se terminent en -ure, etc.), ainsi que des classes spécifiques pour chaque verbe ayant une conjugaison unique tels que v-aller pour aller, v-faillir pour faillir, etc.

Dans les cas où un lemme verbal n'est pas présent dans le Lefff, il lui est attribué la classe standard des verbes du premier groupe (v-er:std) s'il se termine en -er; l'unique classe des verbes du deuxième groupe (v-ir2) s'il se termine en -ir; une des classes principales des verbes du troisième groupe (v-re3) s'il se termine en  $\text{-}vendre^9$ ; et la classe correspondant au verbe paraître (v67) s'il se termine en -paraître. Dans les autres cas, un avertissement est émis et l'entrée est ignorée. Dans la pratique, les très rares cas initialement concernés ont fait l'objet pour la plupart d'un ajout manuel dans le Lefff, ainsi presque plus aucun verbe ne rentre dans cette catégorie  $^{10}$ . De plus, ceci a permis la détection d'erreurs dans les entrées des tables, qui ont été également corrigées  $^{11}$ . Par exemple,  $\langle E \rangle$  liger pour négliger dans la table 6, et en finir pour finir avec l'ajout de en dans la colonne Ppv de la table 1. C'est également le cas de noms dans les tables verbales, comme charge pour charger dans la table 32R3, fossoyeur pour fossoyer dans

<sup>9.</sup> Il faudrait également associer à cette même classe les verbes se terminant par *-tendre*, afin de prendre en compte l'entrée *sous-tendre*.

<sup>10.</sup> Les 2 seules entrées concernées sont *sous-tendre*, comme nous venons de le mentionner, et *contrire*, dont la conjugaison est difficile à trouver puisque ce verbe n'est présent que dans le Dictionnaire du Moyen Français.

<sup>11.</sup> Une comparaison des entrées verbales entre la première version de 2008 et la version 3.3 est réalisée à la section 9.2. Cela ne tient pas compte d'erreurs pouvant avoir été introduites par nous-même lors de la modifications des tables et ayant été corrigées par la suite.

la table 38LD, et rencontre pour rencontrer dans la table 38LR.

Pour les noms, les classes principales sont celles qui produisent deux formes, une au singulier et une au pluriel en ajoutant simplement un s, que ce soit pour les noms masculins (nc-2m) ou féminin (nc-2f). La majorité des noms se terminant en -u, prennent un x au pluriel (nc-u2m). Quelques noms n'ont qu'une seule forme car ils s'écrivent de la même manière au singulier qu'au pluriel (nc-1m) ou nc-1f). D'autres encore n'ont qu'une forme au pluriel (nc-1mp) ou nc-1f). Ensuite, certains noms peuvent s'employer aussi bien au féminin qu'au masculin, avec pour chacun les deux formes singulier et pluriel, ils ont donc quatre formes au total (nc-4). D'autres, se terminent en -s et n'ont que trois formes car la forme au masculin singulier et masculin pluriel est identique (nc-s3). Les noms non trouvés dans le Lefff, sont considérés comme invariables (inv), le nom n'est donc pas fléchi.

#### 8.1.5 Exemples d'entrées complètes

Pour l'entrée *ruisseler* de la table 35L, que nous suivons depuis le début de ce chapitre, le résultat final est alors le suivant :

Pour l'entrée clouer de la table 36SL, mentionnée ci-dessus, le résultat est :

Cette entrée permet de reconnaître par exemple Max a cloué cette planche au mur, mais aussi Max a cloué cette planche.

Prenons comme exemple, le nom prédicatif considération de la table AA. Il a deux constructions définitoires comme on peut le voir dans cet extrait du lexique LGLex:

```
absolute=(construction="true::N1 avoir Det N de N0",
construction="true::N0 avoir Det N Prép N1")
```

Lors de la conversion au format Lefff, cela crée deux entrées avec le même identifiant. La catégorie morphologique est nom commun (cat=nc) et la catégorie syntaxique est cf, désignant un constituant figé séparable du verbe. Dans lightverb, on retrouve la liste des verbes supports, et la redistribution est %default:

La première entrée permet de reconnaître Max a de la considération pour (ce geste+Luc) et la deuxième (Ce geste+Luc) a la considération de Max.

Pour récapituler, une entrée du lexique **intensionnel** <sup>12</sup> contient les informations suivantes :

- l'identifiant de l'entrée : catégorie\_numTable\_numEntrée ;
- une classe morphologique, qui définit le modèle qui construit les formes fléchies en reposant sur les classes flexionnelles du Lefff;
- un poids, qui désigne la fréquence d'apparition d'un mot dans la langue française (dans le but d'aider l'analyseur syntaxique à privilégier une entrée plutôt qu'une autre);
- la forme du lemme incluant les formes préverbales;
- une catégorie syntaxique (v, cf pour un constituant figé séparable du verbe, ou cfi pour un constituant figé inséparable du verbe);
- une catégorie morphologique (cat=v ou cat=nc);
- un cadre de sous-catégorisation initial;
- des informations supplémentaires représentées par des macros;
- une liste des redistributions possibles.

Pour terminer, nous donnons un exemple d'une entrée du lexique **extensionnel** : le participe passé féminin pluriel (*Kfp*) du verbe *clouer* associé à la redistribution passive permettant de reconnaître *Cette planche a été clouées au mur par Max* :

L'objet direct original (Obj) a été transformé par un sujet passif et un agent optionnel (Obl2), réalisé par un syntagme nominal précédé par une préposition (par-sn), a été ajouté.

<sup>12.</sup> Afin de voir d'autres exemples, la section 9.3 montre les entrées verbales *croupir*, *croustiller* et *croûter* de la table 31R dans tous les formats disponibles.

Pour plus de détails, voir l'annexe C.

#### 8.1.6 Conversion des expressions figées

Nous décrivons d'abord la méthode générale adoptée, avant d'évoquer les cas particuliers de certaines tables.

#### Méthode générale

La conversion des expressions figées a d'abord été faite en ne prenant en compte que la construction de base, ce qui a le mérite de couvrir la grande majorité des intitulés des tables, lesquels représentent les différents mots de l'entrée, ainsi que les distributions des constituants libres. Les variantes de constructions et les redistributions ont donc été ignorées.

La conversion des expressions figées du Lexique-Grammaire a déjà été étudié par Laurence et al. (2006), ce qui a permis l'intégration de 1 915 expressions figées dans le Lefff (vC1pC2.ilex, vC1pN2.ilex, avoirC1pC2.ilex, avoirN1pC2.ilex). Voici un exemple d'expression figée du Lefff, sur lequel nous nous sommes basée (vC1pC2.ilex):

Il importe de noter qu'il y a également dans le Lefff des exemples avec verbe support qui pourrait être utilisé comme modèle pour certaines tables en avoir ou  $\hat{e}tre$ , mais ce n'est pas le cas puisqu'on ne les considère pas comme des noms prédicatifs où plusieurs verbes supports seraient possibles, mais comme une expression figée entière. À la différence des tables de noms prédicatifs, le verbe est ici également dans l'entrée (avoirC1pC2.ilex):

Les valeurs par défaut pour les expressions figées sont :

- code de flexion (ou classe morphologique) : 0+; le 0 permet de supprimer le premier mot (car il est en première position, inv+0+ permet de supprimer le deuxième mot, etc.), c'est-à-dire le verbe. En effet, il peut s'insérer des adverbes par exemple entre le verbe et le reste, donc le verbe est dans l'entrée lexicale intensionnelle mais pas extensionnelle. Une séquence se finissant par un + signifie que tous les autres mots sont invariables, sans avoir à écrire 0+inv+inv+inv avec le bon nombre de mots. S'il y a des clitiques figés avec le verbe, on ajoute autant de 0 qu'il y a de clitiques (par exemple, pour l'entrée n'en être pas moins vrai, le code de flexion est 0+0+0+;
- pas de catégorie morphologique;
- catégorie syntaxique : cfi (constituant figé inséparable du verbe);
- tête syntaxique : synt\_head=\$1, ce qui correspond au premier mot, c'est-à-dire le verbe. Au niveau extensionnel, c'est le trait synt\_head qui indique quels sont le ou les verbes possibles comme tête du reste pour former la locution figée complète. Un problème se pose lorsque le premier mot est la négation ou Ppv : il faut rajouter des accolades autour du verbe pour qu'il soit considéré comme premier mot;
- redistribution par défaut : %default.

A propos des entrées, voici ce qui a du être rajouté :

- suppression des  $\langle E \rangle$  présents dans l'entrée. Au maximum 12 suppressions sont possibles puisque la plus longue entrée des expressions figées comporte 12 mots;
- suppression des espaces au début de l'entrée. En effet, dans les tables, beaucoup de mots sont introduits par un espace inutile, mais ceci serait trop long à supprimer manuellement;
- suppression des espaces suivant une apostrophe : c'est le cas pour les négations en n';
- élision de le, la et de, devant une voyelle ou un h. En effet, les déterminants ne tiennent pas compte du mot qui suit. Cette approximation est fausse pour la soixantaine de mots commençant par un h aspiré, malheureusement il n'existe pas d'autre moyen pour les reconnaître.

Cela est sans compter que les entrées n'ont pas encore été corrigées et que certaines contiennent des codes de remplacement, comme par exemple :Nhum ou le déterminant Poss0. Pour ce dernier, on peut ajouter une macro de type @ObjPossSuj qui indiquerait que si le déterminant du Obj est un Poss, il fait référence à l'argument de fonction syntaxique Suj, c'est-à-dire de position 0. Ces entrées posent problème pour la conversion au format Lefff tant qu'un traitement adapté à chaque code de remplacement n'a pas été établi. De plus, les notations de ces codes ont besoin d'être harmonisées (par exemple, lui-0 et Lui-0).

Pour reconnaître ce qui est figé dans la construction de base, il a fallu lister explicitement les motifs (par exemple Det1 C1) à ne pas prendre en compte dans le traitement, puisqu'ils ne donnent aucune autre information que l'ordre des mots, ce qui est déjà contenu dans l'entrée. Il ne faut garder que les informations sur le verbe et sur les arguments libres tels que Prép2 N2 ou Prép3 N3. Les mots de l'entrée sont codés dans lexical-info, y compris les prépositions des arguments libres. La préposition du dernier

argument libre est donc récupérée et ensuite supprimée de l'entrée. Elle constitue en effet le dernier mot de l'entrée, alors que la préposition est codée dans le cadre de sous-catégorisation. La distribution de l'argument N2 ou N3 en question est récupérée par le procédé habituel dans **args**.

Pour les prépositions libres, il y avait confusion entre les prépositions vides et la non existance de l'argument concerné. C'est pourquoi la construction de base de la table ECO qui était Ce être Prép1 Det1 C1 Prép2 Det2 C2 Prép3 N3 alors que le troisième argument n'était pas obligatoire (c'est une affaire qui marche), a été changée en Ce être Prép1 Det1 C1 Prép2 Det2 N2 avec l'ajout de la colonne Ce être Prép1 Det1 C1 Prép2 Det2 C2 Prép3 N3 dans la table qui vaut + lorsqu'au moins l'une des 5 colonnes N3 =: Nhum, N3 =: N-hum, N3 =: ce Qu Pind, N3 =: ce Qu Psubj et N3 =: (de) V-inf W vaut +. De la même manière, les constructions définitoires de la table Z5P étaient N0 être Prép1 Det1 C1 (E+Prép2 N2) et il être Prép1 Det1 C1 (E+Prép2 N2) Qu P alors que le deuxième argument n'était pas obligatoire, elles ont donc été changées en N0 être Prép1 Det1 C1 et il être Prép1 Det1 C1 Qu P. Cela étant accompagné de l'ajout des 2 colonnes N0 être Prép1 Det1 C1 Prép2 N2 et il être Prép1 Det1 C1 Prép2 N2 Qu P qui valent toutes les 2 + lorsque l'une des 2 colonnes N2 =: Nhum et N2 =: N-hum vaut +.

Après ces quelques modifications, on peut établir la règle que lorsqu'une préposition vaut  $\langle E \rangle$ , cela signifie qu'il n'y a pas de préposition introduisant l'argument, mais que l'argument existe quand même, nous l'avons noté  $\langle Obl:sn \rangle$ . Ceci concerne les tables A1PN, CPQ, EPCPN et EPCPQ avec des entrées comme en être à croire Nhum.

Actuellement, 60 tables, sur 69 au total, traités de cette manière donne les bonnes entrées correspondant à la construction de base de la table. Pour beaucoup de constructions, le cadre de sous-catégorisation n'est constitué que du sujet  $(\langle Suj:cln|sn\rangle)$  car tout le reste est figé, seul le sujet est libre.

#### Cas particuliers

Justifions à présent les spécificités des entrées de certaines tables :

- Pour les tables C5, CAN, CDN, CPN, EDN et EPCDN, les compléments de noms (Nc) sont convertis en deuxième argument (N2), car il n'est pas possible dans le Lefff de coder les compléments de noms. Par exemple, la construction N0 V Prép1 Det1 C1 de Nc code un Objde :de-sn, c'est-à-dire un syntagme nominal libre;
- De plus, pour la table CAN qui possède 2 constructions définitoire, une seule construction n'est prise en compte comme construction de base, à savoir N0 V Det1 C1 de Nc, la deuxième (N0 V Det1 C1 à Nc) doit par la suite être prise en compte parmi les variantes possibles. De même, pour la table Z5P, comme cela a été décrit précédemment, c'est uniquement il être Prép1 Det1 C1 Qu P qui est prise en compte, alors qu'il faudrait pouvoir prendre en compte N0 être Prép1 Det1 C1;
- Pour la table EC0, comme vu précédemment, l'unique construction de base prise

en compte est Ce être Prép1 Det1 C1 Prép2 Det2 C2, ce qui signifie que contrairement à ce qui est expliqué, la préposition 3 ne peut pas être supprimée de l'entrée (par exemple, c'est tout pour) puisqu'il manque l'information indiquant qu'elle fait partie d'un troisième argument qui est libre;

- Pour les tables ANP2, C6, CNP2 et ENPC, la construction de base contient un argument libre (N1) directement après le verbe, comme dans N0 V N1 Prép2 Det2 C2. La catégorie syntaxique est donc cf (constituant figé séparable du verbe) au lieu de cfi, ce qui permet d'insérer des mots après le verbe. Cela est possible grâce au code de flexion 0+ qui spécifie que le verbe est supprimé, fléchi et peut être suivi par d'autres mots. La distribution du N1 contenue dans args doit être ignorée puisque cet argument ne peut pas faire partie du cadre de sous-catégorisation s'il n'est pas placé après l'entrée complète;
- table ENPC, De plus, pour la ayant pour construction base N0 être Det1 N1 Prépc Detc Cc, l'argument Det1 N1 est supprimé, avec y compris l'information sur le Det1 qui est figé. Notons également que la construction de base N0 être Det1 N1 Prépc Detc Cc est incompatible avec les 2 colonnes codées dans la table (N0 être Det1 Prépc Detc Cc N1 et N0 être Det1 N1 Prépc Detc Cc) qui codent l'ordre des mots, qui peut être différent de celui de la construction de base. La deuxième colonne dans la table n'est donc pas prise en compte puisqu'il s'agit de la construction de base. Étant souvent codée + et pouvant être poussée lorsque l'autre ordre est accepté, cela reste cohérent :
- Pour les tables C0, C0E, C0Q et certaines entrées de la table CFF, le sujet est figé : pour les tables C0 et C0Q, le sujet est Det0 C0 (dans la construction de base Det0 C0 V Prép1 (Det1 C1+N1) Prép2 N2), pour la table C0E, Conj Prép0 Det0 C0 (dans construction de base Conj Prép0 Det0 C0 Prép1 (Det1 C1+N1) Prép2 N2), et pour la table CFF, Conj Det0 C0 pour certaines entrées (dans construction de base Conj (Det0 C0+N0) V (Det1 C1+N1) Conj-2 Det0-2 C0-2 V-2 Det1-2 C1-2). Les entrées sont donc des entrées verbales codées comme par exemple voici (interj.ilex) :

voici inv

100;Lemma;v;
<Obj:cla|qcompl|scompl|sinf|sn>;
cat=v;%actif

Toutes les valeurs par défaut sont donc modifiées : la catégorie syntaxique est v, la catégorie morphologique est cat=v, la redistribution par défaut est %actif, et le cadre de sous-catégorisation ne contient pas de sujet, mais peut contenir un ou deux compléments lorsque l'argument N1 et/ou Prép2 N2 est libre.

Pour les entrées avec sujets figés, le code de flexion se compose de plusieurs inv (pour chaque mot du sujet figé, deux pour les tables C0 et C0Q correspondant à Det0 C0, et trois pour les entrées de la table CFF acceptant Conj Det0 C0), puis d'autant de  $\theta$  que de clitiques figés avec le verbe, suivi du code de flexion du verbe. La table C0E n'ayant pas de verbe, son code de flexion est inv+;

Pour les tables E01, E0P1 et EC0, le sujet est également figé, mais en fait c'est l'entrée toute entière qui est figée : pour les tables E01 et E0P1, le sujet est Det0 C0 (dans les constructions de base Det0 C0 être Adj1 et

Det0 C0 être Prép1 Det1 C1), et pour la table EC0, Ce (dans la construction de base Ce être Prép1 Det1 C1 Prép2 Det2 C2). Les entrées sont donc des entrées verbales codées comme par exemple  $avoir_{--}AUX$  ( $v_{-}new.ilex$ ):

```
avoir__AUX v2
          600;0;auxAvoir;;
          @active,@avoir,cat=v;
          %default
```

Dans ce cas, les valeurs par défaut deviennent : la catégorie syntaxique est v, la catégorie morphologique est cat=v, le cadre de sous-catégorisation est vide puisqu'il ne contient ni sujet, ni objet puisque l'entrée est entièrement figée, c'est pourquoi la redistribution par défaut est % default.

De même que pour les tables précédentes, le code de flexion se compose de plusieurs *inv* (pour chaque mot du sujet figé, un seul pour la table EC0 pour le sujet Ce, et deux pour les tables E01 et E0P1 correspondant à Det0 C0), puis d'autant de 0 que de clitiques figés avec le verbe, suivi de *v-être* puisqu'il s'agit du verbe *être*.

- En fait, à part la table EC0, pour les tables citées précédemment (C0, C0E, C0Q, CFF, E01 et E0P1), le problème est que certains mots du sujet peuvent être vides. Par exemple, si l'on considère le sujet Det0 C0 des tables E01 et E0P1, le Det0 peut être vide (<E>) ou être composé de plusieurs mots (par exemple, le premier), et le C0 peut également être composés de plusieurs mots (par exemple, action de la justice). Le nombre de mots constituant le sujet figé est donc variable, ce qui rend impossible la conversion au format Lefff, où il est nécessaire de repérer la position du verbe (pour indiquer sa table de flexion), afin de générer toutes les formes fléchies correspondantes. Il faudrait donc ajouter des colonnes catégorisant mieux chaque mot constituant le sujet figé.

Notons également que lorsque le déterminant vaut Det, il peut valoir un ou une pour les noms au singulier mais pas des pour les noms au pluriel (par exemple, l'entrée Det dépenses sont inconsidérées) mais plutôt les, ces, ses, etc. Il faudrait donc définir la liste exacte des déterminants pour les remplacer dans le Lefff;

- Pour la table 31I, même si l'on pourrait croire que le sujet est figé (C0 dans la construction de base C0 V W), il s'agit des verbes impersonnels, le sujet est donc il. Les valeurs par défaut deviennent ici : v pour la catégorie syntaxique, cat=v pour la catégorie morphologique, %actif\_impersonnel pour la redistribution et le cadre de sous-cégorisation ne contient que le sujet avec la réalisation sn. Le code de flexion est calculé comme pour les verbes et correspond à v-er:std car tous les verbes appartiennent au premier groupe. Comme pour les tables de verbes, l'entrée peut contenir des adverbes tels que Advm, jamais, etc., il faut donc prendre en compte uniquement le premier mot de l'entrée, c'est-à-dire le verbe, puisqu'il sera fléchi.
  - Dans la table, en réalité, le sujet il n'est pas accepté pour tous les verbes, donc cette information a été généralisée. En revanche, le pronom ça est accepté pour tous les verbes, ce qui nous a amené à ajouter la macros @impers\_ca dans le Lefff pour pouvoir représenter cette information;
- Pour les tables C0, C0E, C0Q, CFF, CPP, CPPN, CPPQ, CV et Z5D, le problème est plus important car il faudrait dédoubler chacune de ces tables. En effet, elles

comportent dans leur construction de base un + (par exemple, (Det1 C1+N1)), indiquant que l'argument est libre ou figé, ce qui ensuite dépend des entrées. Elles ne peuvent donc pas être traitées de la même manière et la construction de base doit être précisée pour chaque entrée.

Pour terminer, il reste encore un grand nombre de problèmes à résoudre, qui nécessitent une révision complète des tables avant d'obtenir une version des tables d'expressions figées au format Lefff. Notamment, il est nécessaire d'harmoniser les notations des codes de remplacement figurant dans les entrées, d'ajouter des colonnes dans certaines tables ayant un sujet figé afin de repérer la position du verbe et de dédoubler les tables acceptant en parallèle des arguments libres et figés.

## **8.2** Le lexique LGLex-Lefff

Le lexique issu de *LGLex* est appelé *LGLex*-Lefff, pour le différencier du Lefff luimême. Le lexique des verbes simples obtenu contient 22 060 entrées pour 5 736 lemmes verbaux distincts <sup>13</sup>, c'est-à-dire un nombre moyen d'entrées par lemme de 3,85. À titre de comparaison, le Lefff contient seulement 7 072 entrées verbales pour 6 818 lemmes verbaux distincts, soit un nombre moyen d'entrées par lemme de 1,04. Le lexique *LGLex*-Lefff, quoique décrivant moins de lemmes verbaux <sup>14</sup>, est donc beaucoup plus couvrant en termes de constructions syntaxiques, et donc beaucoup plus ambigu. Les lemmes verbaux les plus ambigus dans le Lefff sont tenir et (re)faire (6 entrées), alors que dans le lexique *LGLex*-Lefff, il s'agit des lemmes tenir (53 entrées), jouer (44 entrées) et prendre (35 entrées).

Au niveau extensionnel, le Lefff contient 361 268 entrées, alors que le lexique extrait de LGLex en contient 1 130 960.

Le lexique des noms prédicatifs obtenu contient 28 322 entrées pour 8 491 lemmes distincts (3,34 entrées/lemme). Le Lefff ne contient que 218 entrées de noms prédicatifs (1 entrée/lemme). Au niveau extensionnel, LGLex-Lefff contient 52 517 entrées pour les noms prédicatifs.

L'obtention de ce lexique à partir de *LGLex*, par le processus décrit ici est réalisée par *LGLex2ilex*, un script en Perl d'environ 1 500 lignes. La conversion proprement dite, c'est-à-dire l'exécution du script sur l'ensemble de *LGLex*, prend moins d'une minute. Si une nouvelle version des tables et de la table des classes est publiée, la construction du lexique correspondant au format Alexina est quasiment instantanée, et ne nécessite aucun nouveau développement.

Les détails nécessaires afin de générer le lexique LGLex-Lefff sont expliqués dans l'annexe  $\mathbb{D}$ .

<sup>13.</sup> Le nombre de verbes distincts est identique à celui des tables (à 2 entrées près, cf. 8.1.4). En revanche, le nombre d'entrées ne correspond pas à celui des tables, puisque pour chaque entrée, les constructions trop éloignées de la CBME (non déductibles par une redistribution du Lefff) conduisent à des entrées secondaires avec le même identifiant (cf. cas 5 en 8.1.1).

<sup>14.</sup> Cela est dû aux verbes récents ou techniques présents dans le Lefff.

# Quatrième partie Résultats

# Récapitulatif des travaux effectués

Dans ce chapitre, nous faisons un bilan sur l'avancement des travaux de conversion des tables dans la section 9.1, ainsi que sur l'évolution de la version 3 des tables dans la section 9.2. Enfin, nous montrons un extrait de la table 31R dans tous les formats disponibles actuellement dans la section 9.3.

#### 9.1 Bilan sur l'avancement des travaux de conversion

Reprenons la Tab. 5.1 qui fait l'inventaire complet des tables (classées par catégorie) actuellement développées, pour y ajouter les différents formats auxquels elles ont été converties dans la Tab. 9.1 (Tolone, 2009). Pour chaque ensemble de tables nous indiquons leurs auteurs principaux (cf. la Tab. 5.1 pour les références associées), le nom des tables (cf. la Tab. 5.1 pour une liste plus détaillées, ainsi que le nombre de tables concernées), ainsi que les formats dans lesquels elles sont disponibles actuellement. Nous précisons si elles sont au format Excel, si elles sont incluses dans la table des classes appropriée (cf. section 5.4), si elles sont incluses dans le lexique LGLex (cf. chapitre 7), et enfin si elles sont incluses dans le lexique LGLex-Lefff (cf. chapitre 8).

## 9.2 Évolution de la version 3

Comme nous l'avons mentionné en 5.2.4, les tables disponibles ainsi que les différents lexiques auxquels elles ont été converties (*LGLex* et *LGLex*-Lefff) font partie de la version 3, qui a évoluée depuis septembre 2008. La version 3.3 est disponible depuis le 31 mars 2011 sur le site <a href="http://infolingu.univ-mlv.fr/">http://infolingu.univ-mlv.fr/</a> (Données Linguistiques >

| Auteurs                      | Nom des tables               | Format        | Table          | Lexique  | Lexique     |
|------------------------------|------------------------------|---------------|----------------|----------|-------------|
|                              |                              | Excel         | des classes    | LGLex    | LGLex-Lefff |
|                              | (a) Verbes distribu          | tionnels (sin | nnles)         |          |             |
| M. Gross                     | 1 à 18                       | OK            | OK             | OK       | OK          |
| JP. Boons, A. Guillet,       | 32A 39                       | OK            | OK             | OK       | OK          |
| C. Leclère (BGL)             | 02/1 03                      |               | OIL            |          |             |
| JP. Boons, A. Guillet,       | 31H 35R                      | OK            | OK             | OK       | OK          |
| C. Leclère (BGL)             | 0111 0010                    |               | 011            |          | 011         |
| A. Guillet,                  | 36DT 38LR                    | OK            | OK             | OK       | OK          |
| C. Leclère (BGL)             |                              |               |                | 0 = -    | 0           |
| C. Leclère, A. Borillo (BGL) | 36S                          | OK            | OK             | OK       | OK          |
| C. Leclère (BGL)             | 35RR et 38RR                 | OK            | OK             | OK       | OK          |
| . /                          | (1)                          |               |                |          |             |
|                              | (b) Noms prédicatifs (       | -             | - /            | OTZ      | OTZ         |
| J. Giry-Schneider            | F1A à F91                    | OK            | OK             | OK       | OK          |
| J. Giry-Schneider            | FN à FNPNN                   | OK            | OK             | OK       | OK          |
| A. Meunier                   | AN01 ANSY                    | OK            | OK             | OK       | OK          |
| G. Gross                     | AA IS2                       | OK            | OK             | OK       | OK          |
| J. Giry-Schneider,           | AN07 à AN10                  | OK            | OK             | OK       | OK          |
| A. Balibar-Mrabti            | ANDN ANDN                    | 0.17          | 017            | 0.17     | 0.17        |
| J. Giry-Schneider            | ANDN et ANSN                 | OK<br>OK      | OK<br>OK       | OK       | OK          |
| D. de Négroni-Peyre          | PSY et SYM                   |               |                | OK       | OK          |
| R. Vivès                     | APE1 à APP3                  | OK            | OK             | OK       | OK          |
| J. Labelle                   | ANA ANSU                     | OK            | OK             | OK       | OK          |
| L. Pivaut                    | FD1 à FD4                    | En cours      | En cours       | En cours | En cours    |
| (c) Expre                    | ssions figées (principal     | ement verba   | les et adjecti | vales)   |             |
| JP. Boons, A. Guillet,       | 31I                          | OK            | OK             | OK       | En cours    |
| C. Leclère (BGL)             |                              |               | 0 ==           | 0 = -    |             |
| M. Gross                     | A1 YA                        | OK            | OK             | OK       | En cours    |
| M. Gross                     | EAPC EPA                     | OK            | OK             | OK       | En cours    |
| M. Gross                     | EPAC à EPDETC                | OK            | OK             | OK       | En cours    |
| M. Gross                     | E1 EDN                       | OK            | OK             | OK       | En cours    |
| J. Giry-Schneider            | FC à FCPNN                   | OK            | OK             | OK       | En cours    |
| L. Danlos                    | Z à ZS                       | En cours      | En cours       | En cours | En cours    |
|                              | (1) 4.1 1 (1                 | 1 / .         | \ C \ ( )      |          |             |
| CMI: DI                      | (d) Adverbes (simple ADVAGE) |               | , - ,          | OIZ      |             |
| C. Molinier, F. Levrier      | ADVMF à ADVPS                | OK            | OK             | OK       | /           |
| M. Gross                     | PAC à PVCO                   | OK            | OK             | OK       | /           |
|                              | (e) Adjectifs préd           | icatifs (simp | oles)          |          |             |
| L. Picabia                   | ADJ1 à ADJ13                 | /             | /              | /        | /           |
| J. Giry-Schneider            | ADJ01 à ADJSYM               | En cours      | /              | /        | /           |
|                              | (f) Adjectifs non pr         | édicatifs (si | mples)         | <u> </u> |             |
| E. Laporte                   | ADJLOCTABLE                  | OK            | /              | /        | /           |
| J. Giry-Schneider            | DEDJA et DADJI               | En cours      | /              | /        | /           |
| o. Giry Dominiaci            | DEDOM OF DADOI               | Lii cours     | /              | /        | /           |

Table 9.1: Inventaire des tables du Lexique-Grammaire et avancement des travaux de conversion vers des formats électroniques exploitables

Lexique-Grammaire > Téléchargement), accompagnée des outils de conversion (LGEx-tract et LGLex2ilex). La Tab. 9.2 récapitule l'évolution de la version  $3^{1}$ .

Les catégories couvertes par les tables, au format  $CSV^2$ , et par le lexique LGLex, au format texte et XML, sont les verbes, les noms prédicatifs, les expressions figées et les adverbes. Des entrées supplémentaires de verbes, expressions figées et adjectifs prédicatifs ont été extraites de certaines tables (cf. section 6.6). De plus, les verbes et les noms prédicatifs sont au format LGLex-Lefff (intensionnel et extensionnel).

Parmi les informations sémantiques codées dans les tables, le format *LGLex-Lefff* garde celle qui est la plus complète, à savoir si un syntagme nominal peut être humain et/ou non humain (macros @SujNhum, @ObjàN-hum, etc.).

De plus, un README est disponible pour chacun des deux formats de lexique en français et en anglais (voir les annexes A et C), de même que pour chacun des deux outils de conversion (voir les annexes B et D), et enfin pour les tables afin de présenter leur format, leur codage, ainsi que celui de la table des classes, et d'y inclure toutes les références complètes. On spécifie également pour chacune des références, le nombre de tables concernées, ainsi que la liste complète des tables (cf. la Tab. 5.1).

Enfin, en plus des tables, nous avons également une table des classes par catégorie, ainsi que pour les verbes, la documentation de toutes les propriétés syntaxico-sémantiques en français et en anglais (voir l'annexe E), l'ordre de priorité dans le classement des verbes accompagné des formules définitoires de chaque table (voir l'annexe F) et l'arbre de classement (voir l'annexe G).

Les entrées verbales ont subit un grand nombre de modifications, notamment lors de la mise en correspondance des tables et de l'index éléctronique, tout en tenant compte des fiches cartonnées (cf. 5.5.2), puis de la conversion au format Lefff qui a permis la détection d'erreurs (cf. 8.1.4). Nous avons effectué une comparaison entre les entrées verbales de la première version de septembre 2008 (provenant de l'ensemble des tables, contrairement à ce qui a été diffusé) et celles de la version 3.3 de mars 2011. En 2008, nous avions 13 327 entrées verbales pour 5 714 verbes distincts (dans 59 tables 3), ce qui totalise 540 nouvelles entrées verbales, dont 24 verbes distincts par rapport à la version 3.3. Parmi ces verbes distincts, présentés à la Tab. 9.3, on distingue 9 verbes supprimés (ayant été corrigés et correspondant pour la plupart à un verbe déjà existant), 8 verbes corrigés et 33 verbes ajoutés.

<sup>1.</sup> Signalons que le site http://www-igm.univ-mlv.fr/~tolone/recherche.php contient également la dernière version diffusée, ainsi que l'ensemble des versions précédentes de la version 3 présentées à la Tab. 9.2.

<sup>2.</sup> Le format CSV (voir http://fr.wikipedia.org/wiki/Comma-separated\_values) permet de représenter les tables indépendamment du logiciel utilisé (Microsoft Excel, OpenOffice.org Calc, LibreOffice Calc, Gnumeric, etc.). Le logiciel doit cependant gérer l'Unicode, sinon des caractères incorrects peuvent apparaître. L'avantage est que c'est un format texte, il est donc facile de comparer différentes versions, ce qui n'est pas possible avec le format Excel.

<sup>3.</sup> Rappelons que les nouvelles tables sont : 2T, provenant de la division de la table 2; 32D, créée parallèlement à la table 32A; 35LD, 35LS et 35LR, provenant de la division de la table 35L; 38LHD, 38LHS et 38LHR, provenant de la division de la table 38LH.

| Versions                | Tables   | LGLex  | LGLex-Lefff  |
|-------------------------|--|--|--|
| 3.3<br>(31-03-2011)     | Format CSV:  - verbes (100%)  - noms prédicatifs (100%)  - expressions figées (100%)  - adverbes (100%)  | Format texte/XML avec README (FR/EN):  - verbes (100%) - noms prédicatifs (100%) - expressions figées (100%) - adverbes (100%) | Format intensionnel/ extensionnel avec README (FR/EN): - verbes (100%) - noms prédicatifs (100%)           |
|                         | - 4 tables des classes Ajouts verbes :   | Outil LGExtract Entrées suppl. :   | Outil LGLex2ilex   |
|                         | <ul> <li>ajout de propriétés</li> <li>doc. propriétés</li> <li>formules définitoires</li> <li>arbre classement</li> <li>Ajouts adverbes :</li> <li>propriétés paraphrases</li> </ul> | <ul> <li>verbes (100%)</li> <li>expressions figées (100%)</li> <li>adj. prédicatifs (100%)</li> </ul>                          |  |
| 3.2<br>(30-06-2010)     | Format Excel:  - verbes (60%)  - noms prédicatifs (60%)  - expressions figées (60%)  - adverbes (100%)   | Format texte/XML avec README (FR/EN):  - verbes (60%) - noms prédicatifs (60%) - expressions figées (60%) - adverbes (100%)    | Format intensionnel/<br>extensionnel<br>avec README (FR/EN):<br>– verbes (60%)<br>– noms prédicatifs (60%) |
|                         | Ajouts:  - changements d'intitulés Ajouts verbes:  - ajout d'entrées - codage de prépositions  | Entrées suppl. :  - verbes (60%)  - expressions figées (80%)  - adj. prédicatifs (100%)  | Ajouts verbes:  - macros @SujNhum, @ObjàN-hum, etc. = syntagme nominal humain et/ou non humain             |
| 3.1<br>(27-11-2009)     | Format Excel:  - verbes (60%)  - noms prédicatifs (60%)  | Format texte/XML<br>avec README (FR/EN) :<br>— verbes (60%)<br>— noms prédicatifs (60%)  | Format intensionnel:  - verbes(60%)  |
| 3.0<br>(18-12-2008)     | /  | Format texte/XML:  - verbes (60%)  - noms prédicatifs (60%)  | /  |
| 3.alpha<br>(08-09-2008) | /  | Format XML:  - verbes (60%)  - noms prédicatifs (60%)  | /  |

TABLE 9.2: Évolution de la version 3

| Verbes supprimés | Verbes corrigés  | Verbes ajoutés     |
|------------------|--|--------------------|
| bailler          | $balloter \rightarrow ballotter$   | affrioler          |
| cafeter          | $fossoyeur \rightarrow fossoyer$   | aponter            |
| charge           | $godeliser \rightarrow g\ddot{o}deliser$   | approximer         |
| énupler          | $libéller \rightarrow libeller$  | attitrer           |
| fiche            | $pied\pounds$ £au-cuter $\rightarrow$ $pied$ -au-cuter                                   | avérer             |
| fouire           | sous-payer $\rightarrow$ sous-tendre   | barbifier          |
| qoranniser       | $théatráliser \rightarrow théatraliser$  | bicher             |
| rencontre        | $\operatorname{vert} \pounds \operatorname{de-griser} \to \operatorname{vert-de-griser}$ | coraniser          |
| sous-employer    |  | courser            |
|                  |  | cuveler            |
|                  |  | dégotter           |
|                  |  | désaccoupler       |
|                  |  | droper             |
|                  |  | ébaubir            |
|                  |  | enchrister         |
|                  |  | gasconner          |
|                  |  | infibuler          |
|                  |  | insécuriser        |
|                  |  | institutionnaliser |
|                  |  | iodler             |
|                  |  | molarder           |
|                  |  | narrer             |
|                  |  | n-upler            |
|                  |  | raper              |
|                  |  | raplatir           |
|                  |  | rassurer           |
|                  |  | reconstruire       |
|                  |  | renauder           |
|                  |  | rossignoler        |
|                  |  | rouscailler        |
|                  |  | skier              |
|                  |  | ventriloquer       |
|                  |  | zieuter            |

Table 9.3: Comparaison entre les verbes distincts de la première version de 2008 avec ceux de la version 3.3

# 9.3 Extraits de la table 31R dans tous les formats disponibles

#### 9.3.1 Table en version 1, 2 et 3

La Fig. 9.1 représente un extrait de la table 31R en version 1, telle qu'elle est publiée dans la littérature (Boons et al., 1976b). Comme déjà exliqué en 5.2.4, on peut y voir des cartouches horizontaux, qui regroupent une famille de propriétés, ainsi que des dépendances entre propriétés. En, effet, les six premières colonnes sont des propriétés distributionnelles de l'argument N0, comme l'indique le cartouche horizontal intitulé N0. De plus, l'intitulé N0 =: Npc (où Npc dénote le corps ou une partie du corps d'une personne) dépend de l'intitulé N0 =: Nhum, ce qui est représenté par le deuxième cartouche vertical inclus dans le premier. Notons que la construction de base décrite dans (Boons et al., 1976b) (p. 262) est N0 V.

La table 31R en version 2 n'est disponible pas site http://infolingu.univ-mlv.fr (Données Linguistiques Lexique-Grammaire > > Visualisation) car elle ne fait pas partie des 60% librement distribué.

La table 31R en version 3 (actuelle), disponible sur le site, est montrée à la Tab. 9.4 (avec l'ensemble de ses propriétés) pour les deux verbes croupir et croustiller, présents à Fig. 9.1 et pour le verbe croûter qui a été ajouté à la table depuis et qui n'a pas encore été codé (codage ~). Remarquons que le verbe cuver n'est plus dans la table 31R actuelle, il figure dans la table 32R2 (Max cuve son vin) et 38LR (On a cuvé le moût dans la cuve). On peut voir également que la propriété N actif V N0 a été ajoutée dans la table sans avoir été codée, ce qui explique son codage ~.

Les colonnes Ppv =: se figé, Ppv =: en figé, Ppv =: y figé, Ppv =: Neg et Neg ont été ajoutée à la version 3 avec un codage binaire, codage qui doit concorder avec les informations contenues dans la colonne <ENT>Ppv, laquelle n'est gardée que pour des raisons de lisibilité (cf. section 3.2). Les colonnes Aux =: avoir, Aux =: être et N0 être V-n (forme V-n) ont été ajoutées lors de la réintégration du codage de certaines informations concernant les auxiliaires, les V-n et la traduction en anglais des entrées (<ENGLISH>) dans les tables de verbes (Paumier, 2003). L'intitulé il V N0 W ayant la même signification que l'intitulé [extrap] présent dans les tables de M. Gross, la colonne a été harmonisée (cf. 5.3.2). Enfin, certaines propriétés concernant les parties du corps ont été supprimées des tables car elles étaient trop productives et non spécifiques à quelques classes particulières. De plus, elles sont ignorées lors de la conversion au format LGLex, tout comme les propriétés concernant les V-n (cf. section 7.3).

Il faut ajouter à cette table le codage de la table des classe à la Fig. 9.5, avec les 33 propriétés que nous avons jugées pertinentes pour la table 31R sur les 551 propriétés des tables verbales (le codage des propriétés supprimées étant toutes codées — ou?). Cela explique par exemple la disparition de la colonne N0 =: N-hum dans la table, qui est codée + dans la table des classes, puisque son codage est + pour l'ensemble des entrées. De même, cela permet à la construction de base N0 V d'être explicitement codée. Toutes

|   |              | N               | 0                    |                  |             |             |              |                         |        |   | П         |
|---|--------------|-----------------|----------------------|------------------|-------------|-------------|--------------|-------------------------|--------|---|-----------|
| п | $N_0 = N$ pc | $N_0 = N - hum$ | $N_0 = N \text{ nr}$ | $N_0 = V \Omega$ | $N_0 = V-n$ |             | No est V-ant | N <sub>0</sub> est V pp | pc lui | 1 | il V No Ω |
| - | +            | +               | -                    | -                | -           | croupir     | +            | +                       | -      | - |           |
| - | -            | +               | -                    | -                | -           | croustiller | +            | -                       | +      | - | ٠         |
| - | -            | +               | -                    | -                | -           | cuver       | -            | +                       | -      | - | +         |

FIGURE 9.1: Extrait de la table 31R des verbes distributionnels (version 1)

| N0 =: Nhum | N0 =: Nnr | N0 =: V-inf W | N0 être V-n | <ent>Ppv</ent> | Ppv =: se figé | Ppv =: en figé | Ppv =: y figé | Ppv =: Neg | <ent>V</ent> | Neg | Aux =: avoir | Aux =: être | N0 être V-ant | N0 être Vpp | N0 V de N0pc | [extrap] | N actif V N0 | N0 être V-n (forme V-n) | <0PT>                |
|------------|-----------|---------------|-------------|----------------|----------------|----------------|---------------|------------|--------------|-----|--------------|-------------|---------------|-------------|--------------|----------|--------------|-------------------------|----------------------|
| _          | $\exists$ |               | =           | <e></e>        | -              | _              | -             | $\exists$  | croupir      | _   | +            | _           | +             | +           | -            | +        | >            | $\langle E \rangle$     | L'eau croupit        |
|            | -         |               | -           | <e></e>        | -              | _              | _             | -          | croustiller  | -   | +            | _           | +             | -           | -            | +        | ~            | $\langle E \rangle$     | Le gâteau croustille |
| $\sim$     | $\sim$    | >             | $\sim$      | <e></e>        | _              | _              | _             | _          | croûter      | _   | +            | _           | $\sim$        | $\sim$      | $\sim$       | $\sim$   | $\sim$       | $\langle E \rangle$     | Le savon croûte      |

Table 9.4: Extrait de la table 31R des verbes distributionnels (version 3)

les colonnes présentes dans la table 31R sont codées o dans la table des classes, puisque leur valeur varie en fonction des entrées. Certaines colonnes ont été codées — comme par exemple, le passif ou la distribution Nnc du N0. D'autres doivent être codées (codage O), comme la traduction en anglais de chaque entrée (<ENGLISH>). Enfin, d'autres ont un codage qui reste à déterminer (codage?), par exemple la construction N0 être V-eux W.

#### **9.3.2 Lexique** LGLex

Voici l'extrait du lexique LGLex correspondant aux entrées verbales croupir, croustiller et croûter de la table 31R. On peut voir que l'entrée croûter (ayant le statut **to encode**) n'est pas complète car elle n'est pas codée dans la table, mais elle contient tout de même les informations codées dans la table des classes, à savoir sa construction de base N0 V et la propriété définitoire N0 =: N-hum. Les deux autres entrées (ayant le statut **to complete**) sont codées dans la table, à part pour la propriété N actif V N0, qui n'est codée pour aucune entrée (codage  $\sim$ ) :

| Propriété \ table              | V-31R |
|--------------------------------|-------|
| [extrap]                       | 0     |
|                                | _     |
| [passif de] [passif par]       | _     |
| <english></english>            | O     |
| <ent>Ppv</ent>                 | 0     |
| <ent>V</ent>                   | О     |
| <opt></opt>                    | О     |
| Aux =: avoir                   | О     |
| Aux =: être                    | О     |
| N0 =: chemin                   | ?     |
| N0 =: Nhum                     | О     |
| N0 =: N-hum                    | +     |
| N0 =: N-hum métaphore          | ?     |
| N0 =: Nnc                      | _     |
| N0 =: Nnr                      | О     |
| N0 =: Qu P                     | ?     |
| N0 =: V-inf W                  | О     |
| N0 être V-ant                  | О     |
| N0 être V-eux W                | ?     |
| N0 être V-n                    | О     |
| N0 être V-n (forme V-n)        | О     |
| N0 être Vpp                    | О     |
| NO V                           | +     |
| N0 V de N0pc                   | О     |
| N actif V N0                   | О     |
| Neg                            | О     |
| Ppv =: en figé                 | О     |
| Ppv =: la figé                 | _     |
| Ppv =: le figé Ppv =: les figé | _     |
| Ppv =: les tige                | _     |
| Ppv =: Neg                     | 0     |
| Ppv =: se figé                 | 0     |
| Ppv =: y figé                  | О     |

TABLE 9.5: Extrait de la table des classes verbes distributionnels

```
dist=(comp=[cat="NP",nothum="true",
                    introd-prep=(),introd-loc=(),
                    origin=(orig="NO =: N-hum")])])
 all-constructions=[absolute=(construction="true::NO V",
                              construction="o::NO être V-ant",
                              construction="o::NO être Vpp"),
                    relative=(construction="[extrap]")]
 example=[example="L'eau croupit"]
ID=V_31R_78; status=to complete
lexical-info=[cat="verb", verb=[lemma="croustiller"],
              aux-list=(avoir="true"),prepositions=(),locatifs=()]
args=(const=[pos="0",
             dist=(comp=[cat="NP",nothum="true",
                   introd-prep=(),introd-loc=(),
                   origin=(orig="NO =: N-hum")])])
all-constructions=[absolute=(construction="true::NO V",
                             construction="o::NO être V-ant"),
                   relative=(construction="[extrap]")]
example=[example="Le gâteau croustille"]
ID=V_31R_79; status=to encode
lexical-info=[cat="verb", verb=[lemma="croûter"],
              aux-list=(avoir="true"),prepositions=(),locatifs=()]
args=(const=[pos="0",
             dist=(comp=[cat="NP",nothum="true",
                   introd-prep=(),introd-loc=(),
                   origin=(orig="NO =: N-hum")])])
all-constructions=[absolute=(construction="true::NO V"),
                   relative=()]
example=[example="Le savon croûte"]
```

#### **9.3.3 Lexique** LGLex-Lefff

Voici les entrées verbales croupir, croustiller et croûter de la table 31R au format Lefff. On peut voir que les deux entrées des verbes croupir et croustiller sont identiques alors que dans les tables, la construction N0 être Vpp les différencie. Cette propriété n'est en effet pas prise en compte lors de la conversion. En revanche, on voit que l'entrée du verbe croûter ressemble également aux autres, mais n'a pas la redistribution  $\%actif\_impersonnel$ , la colonne [extrap] n'étant pas codée (codage  $\sim$ ) pour cette entrée :

## Chapitre 9 Récapitulatif des travaux effectués

# 10

# Intégration dans FRMG et évaluation

La section 10.1 montre comment le lexique *LGLex*-Lefff a été couplé avec l'analyseur syntaxique à grande échelle FRMG (cf. section 4.2), comme nous l'avons expliqué dans Sagot et Tolone (2009b); Tolone et Sagot (2011), en expliquant également les raisons du choix de l'analyseur. La section 10.2 évalue cet analyseur sur le corpus de référence de la première campagne d'évaluation Passage de 2007, en comparant sa version basée sur le Lefff avec notre version reposant les entrées des verbes simples et des noms prédicatifs des tables du Lexique-Grammaire converties, comme nous l'avons initialement fait pour les verbes sur le corpus de référence de la campagne EASy (Sagot et Tolone, 2009a; Tolone et Sagot, 2011). La section 10.3 présente la fouille d'erreurs effectuée sur le corpus EASy. La section 10.4 présente l'évaluation manuelle réalisée pour valider la qualité des analyses, avant de conclure dans la section 10.5.

# 10.1 Intégration dans l'analyseur syntaxique FRMG

Nous avons réalisé l'intégration des tables dans l'analyseur FRMG, afin d'évaluer leur impact lors d'une l'analyse. Les raisons qui nous ont poussée à choisir cet analyseur sont les suivantes :

- sa disponibilité, contrairement à Cordial de l'entreprise Synapse, le premier système de la campagne d'évaluation Passage de 2007 (cf. chapitre 2);
- son formalisme TAG, qui est lexicalisé et traite les mots composés, et qui a donc besoin d'un lexique à large couverture;
- ses performances, puisque lors de la campagne Passage de 2007, il est troisième sur les dépendances (dans le groupe au-dessus de 60%);
- son amélioration entre la campagne EASy de 2004 et Passage de 2007, en particulier sur la désambiguïsation et la conversion vers le format de la campagne, puisqu'il

passe de 69% à 89% pour les constituants et de 41% à 63% pour les dépendances. De plus, depuis la campagne de 2007, il s'est encore amélioré de 6% pour les constituants et de 7% pour les dépendances, notamment par l'augmentation du nombre d'analyses complètes;

- son utilisation par une large communauté et la bonne interaction entre les utilisateurs et le développeur;
- son lexique, le Lefff, qui est un lexique à large couverture, utilisé également par une large communauté.

L'intégration du lexique LGLex-Lefff dans l'analyseur FRMG est immédiate : FRMG Lexer fait appel à une base de données lexicales construite à partir du Lefff. Il suffit de remplacer les entrées des verbes simples du Lefff par celles du lexique LGLex-Lefff, d'ajouter les entrées des noms prédicatifs du lexique LGLex-Lefff, absentes du Lefff, et de conserver les autres entrées du Lefff. Après avoir construit la base de données lexicales correspondante, il faut seulement spécifier à FRMG d'utiliser cette dernière. Le résultat est une variante de l'analyseur FRMG, que nous notons  $FRMG_{LGLex}$ , par opposition à la variante standard notée  $FRMG_{Lefff}$ .

FRMG étant en constante amélioration, l'intégration du lexique LGLex-Lefff a permis de déceler quelques problèmes qui ont été corrigés par Éric de la Clergerie. Les modifications ont eu lieu à divers niveaux :

- dans la méta-grammaire FRMG : gestion optionnel/non optionnel;
- dans FRMG Lexer : résolution des problèmes de réalisation des arguments ;
- dans le Lefff : ajout de nouvelles prépositions codées dans les tables de verbes (comme *chez* pour le verbe *susciter*).

# 10.2 Évaluation et discussion

Nous avons évalué  $FRMG_{Lefff}$  et  $FRMG_{LGLex}$  en analysant la partie annotée manuellement pour la première campagne Passage de 2007, composée de 4 706 phrases du corpus EASy de styles variés (cf. 2.1.2). Avant de discuter des résultats de cette expérience, certaines précautions sont à prendre :

- le processus de conversion décrit ici et son implémentation contiennent certainement des erreurs, de plus, nous évaluons FRMG lorsqu'il utilise les entrées converties à partir des tables, et non pas les entrées telles qu'elles sont dans les tables;
- la majorité des noms prédicatifs n'ont pas pu être évalués car FRMG ne prend que ceux n'ayant pas de déterminant;
- la campagne Passage ne permet pas d'évaluer toutes les informations contenues dans les tables (informations sémantiques par exemple)
- le Lefff a été développé en parallèle aux campagnes EASy et Passage, contrairement aux tables; certains choix faits dans le guide des annotations syntaxiques de référence PEAS¹ ont pu influencer certains choix faits dans le développement du Lefff, alors que ce n'est évidemment pas le cas pour les tables;

<sup>1.</sup> http://www.limsi.fr/Individu/anne/Guide/PEAS\_reference\_annotations\_v2.2.html

- LGLex a été complété par diverses entrées verbales venant du Lefff, qui ne font pas partie du lexique LGLex : entrées pour les auxiliaires et semi-auxiliaires, certains verbes à montée, les verbes impersonnels et les entrées pour les têtes syntaxiques des constructions à verbe support ; il se peut que d'autres entrées soient encore à rajouter. De plus, toutes les entrées verbales non codées dans les tables (codage ∼) manquent également.

Les résultats comparatifs sur les constituants et les relations (dépendances entre mots pleins) entre ces deux analyseurs sont donnés à la table  $10.1^2$ , avec le détail pour quelques sous-corpus illustratifs. Les résultats sont donc pour l'instant légèrement meilleurs pour FRMG<sub>Lefff</sub>, mais également bons pour FRMG<sub>LGLex</sub>. En effet, une f-mesure pour les relations au-dessus de 60% est meilleure que les résultats de FRMG avec le Lefff lors de la campagne de 2007 (59,65% de f-mesure pour 56% de couverture). Néanmoins, les derniers points de f-mesure découle d'une adaptation plus fine entre la grammaire et le lexique, et de la recherche des erreurs ou incomplétudes lexicales. Il est en effet normal que tout lexique possède des entrées erronées qu'il est difficile de trouver.

De plus, même si les résultats ne sont pas meilleurs, nous ne pensons pas que cela remette en question la pertinence de l'utilisation des tables du Lexique-Grammaire en analyse syntaxique, notamment au vu des précautions ci-dessus. En particulier, nous restons convaincue que l'utilisation d'une ressource lexicale aussi riche que possible reste un moyen efficace pour améliorer la qualité d'un analyseur syntaxique, comme l'ont montré par exemple la mise en œuvre des travaux décrits dans Sagot et de La Clergerie (2008). On peut toutefois constater que les temps d'analyse sont plus deux fois plus élevés avec  $FRMG_{LGLex}$  qu'avec  $FRMG_{Lefff}$  (temps médian par phrase de 0,62 s contre 0,26 s), ce qui provient certainement du nombre d'entrées par lemme qui est trois plus élevé dans LGLex que dans le Lefff, comme nous l'avons mentionné dans la section 8.2. Du reste, ce temps d'analyse plus élevé conduit nécessairement à un plus grand nombre d'échecs d'analyse par dépassement du délai maximum autorisé, ce qui conduit à la construction d'analyses partielles, nécessairement de moins bonne qualité.

Sur deux sous-corpus, c'est toutefois  $FRMG_{LGLex}$  qui obtient les meilleures évaluations en constituants. De même, les résultats sur les relations sont meilleurs avec  $FRMG_{LGLex}$  sur un sous-corpus. L'analyse des résultats montre les faits suivants :

- FRMG<sub>LGLex</sub> donne de meilleurs résultats que FRMG<sub>Lefff</sub> pour certaines relations, comme modifieur d'adjectif (MOD-A) et modifieur d'adverbe (MOD-R), mais également pour deux relations pour lesquelles les résultats sont mauvais d'un côté comme de l'autre : modifieur de préposition (MOD-P) et apposition (APP);
- la relation attribut du sujet ou de l'objet (ATB-SO) est celle pour laquelle la différence en rappel est la plus importante (34,0% contre 58,4%);
- le degré d'ambiguïté lexicale, bien plus élevé dans  $FRMG_{LGLex}$  que dans  $FRMG_{Lefff}$ , conduit à un taux d'ambiguïté plus grand au niveau de l'analyseur, et donc d'autant

<sup>2.</sup> Ces mesures sont calculées avec les outils d'évaluation propres à l'INRIA, qui donnent généralement des valeurs plus faibles de quelques points que les résultats officiels. En effet, les mesures des campagnes EASy et Passage sont un peu plus laxistes, par exemple en autorisant des variations sur les limites des constituants. Enfin, il est à noter que les données de références ont été en partie corrigées au cours des années.

|                     | Const          | ituants        | Relations      |                |  |  |  |
|---------------------|----------------|----------------|----------------|----------------|--|--|--|
| Sous-corpus         | $FRMG_{Lefff}$ | $FRMG_{LGLex}$ | $FRMG_{Lefff}$ | $FRMG_{LGLex}$ |  |  |  |
| general_lemonde     | 88.22%         | 84.60%         | 62.73%         | 59.01%         |  |  |  |
| litteraire_2        | 88.91%         | 88.46%         | 65.28%         | 62.43%         |  |  |  |
| mail_9              | 82.60%         | 81.90%         | 58.55%         | 56.00%         |  |  |  |
| medical_3           | 85.04%         | 85.89%         | 64.79%         | <b>65.26</b> % |  |  |  |
| oral_delic_4        | 78.80%         | 81.79%         | <b>51.67</b> % | 51.14%         |  |  |  |
| questions_amaryllis | <b>91.30</b> % | 90.73%         | 66.56%         | 64.77%         |  |  |  |
| total               | 87.05%         | 85.53%         | 63.10%         | 60.25%         |  |  |  |

Table 10.1: Résultats comparatifs de  $FRMG_{Lefff}$  et  $FRMG_{LGLex}$  sur le corpus de référence de la première campagne Passage, exprimé en terme de f-mesure.

plus de risque de se tromper au moment de la désambiguïsation. En effet, comme vu en 4.2.3, le désambiguïsateur utilisé par FRMG est à base de règles heuristiques pondérées <sup>3</sup>.

Ainsi, le nombre élevé d'arguments verbaux listés dans les cadres de sous-catégorisation de LGLex conduit à induire en erreur l'heuristique de désambiguïsation habituelle selon laquelle «on préfère les arguments aux modifieurs» : tout syntagme pouvant être analysé comme un argument verbal a tendance à l'être. Dans une phrase comme [...] on estime que cette décision [ferait] dérailler le processus de paix,  $FRMG_{LGLex}$  fait de de paix un argument de estimer (estimer qqch de qqn), là où  $FRMG_{Lefff}$  ne se trompe pas. Notons que si les traits sémantiques étaient pris en compte dans l'analyseur, LGLex ne conduirait pas à une erreur, puisque la table 6 fournit la construction N0 V N1 de N2hum et le substantif paix n'est pas humain, trait sémantique qui devrait également figurer dans le lexique des substantifs.

On peut faire le constat suivant : de nombreuses phrases reçoivent une analyse complète par  $FRMG_{LGLex}$  alors que ce n'est pas le cas par  $FRMG_{Lefff}$ , et inversement. Par exemple, sur le sous-corpus  $general\_lemonde$ , 177 phrases sont entièrement reconnues par les deux analyseurs, 85 seulement par  $FRMG_{Lefff}$ , 76 seulement par  $FRMG_{LGLex}$ , et 111 par aucun des deux. L'expérience montre que la qualité des résultats est très supérieure, de plus de 10 points en moyenne, sur les phrases analysées complètement par rapport à celles qui reçoivent plusieurs analyses partielles. On peut donc envisager de construire un système très simple qui analyserait une phrase avec chacun des deux analyseurs, et qui, dans les cas où seulement l'un des deux propose une analyse complète, ne garde que celle-ci (ce qu'il faut faire dans les autres cas reste à étudier). Les résultats sont susceptibles d'être meilleurs que l'usage exclusif de l'un ou l'autre.

Il importe également de bénéficier de cette complémentarité entre les deux ressources. Il est donc intéressant d'étudier les différences entre les erreurs faites par chacun de ces deux analyseurs, y compris au moyen de techniques automatiques (Sagot et de La Cler-

<sup>3.</sup> On peut penser qu'un modèle statistique de désambiguïsation pourrait mieux gérer l'ambiguïté provenant de LGLex. Nous ne sommes pas en mesure de confirmer ou d'infirmer empiriquement cette hypothèse.

gerie, 2008), comme nous allons le voir à présent. Le but étant d'améliorer les différentes ressources, voire de détecter automatiquement des erreurs dans les lexiques.

#### 10.3 Fouille d'erreurs

Nous avons effectué une fouille d'erreurs dans les sorties de l'analyseur syntaxique FRMG sur les verbes du corpus EASy <sup>4</sup>. Elle reprend les principes de fouilles d'erreurs présentés dans Sagot et de La Clergerie (2008), tout en l'adaptant. En effet, dans ce travail, l'objectif était en première approximation d'identifier les formes dont la présence dans une phrase tend à rendre la phrase inanalysable <sup>5</sup>. Pour cette expérience, cet objectif est adaptée afin d'identifier les entrées d'un lexique **hyp** qui semblent dégrader les performances de FRMG comparativement à un lexique de référence **ref**, ici le Lefff: l'idée est de trouver les formes, et plus précisément les formes verbales, dont la présence dans une phrase analysable avec le lexique de référence **ref** tend à rendre cette phrase inanalysable avec le lexique **hyp**.

Le corpus EASy est trop petit pour obtenir des statistiques suffisantes pour un diagnostic complet des ressources. Mais l'algorithme ne nécessitant pas de disposer d'un corpus de référence (seule l'analysabilité, c'est-à-dire la couverture, étant exploitée), nous pourrons dans un avenir proche l'utiliser sur un corpus bien plus volumineux (Tolone et al., 2011).

Les principaux suspects dans LGLex, si l'on regarde en détail les 5 premiers verbes présents dans les 12 phrases qui n'ont pas été analysées, sont :

- s'accroître dans la population s' accroît plus rapidement dans les régions les plus pauvres du monde, car la forme pronominale est manquante;
- ressaisir dans Tout ce passé me ressaisit avec une force extrême, ou dans S' écria M Levrault tombant en arrêt et déjà prêt à ressaisir sa proie, car la forme non pronominale est manquante;
- soupçonner dans il ne devinait rien et ne soupçonnait pas qu' il pût y avoir quelque anguille sous roche, car le verbe n'est pas codé avec une complétive comme premier complément : l'entrée appropriée est celle de la table 6 (illustrée par l'exemple Max soupçonne qu'il va pleuvoir), mais fait partie des entrées qui ne sont pas codées (codage ∼);
- impliquer dans Son évaluation implique d' inclure ces patients dans des essais thérapeutiques, car il y a une erreur de conversion au format Lefff: cette entrée vient de la table 10 (Ceci implique pour Max que Léa le quittera) qui accepte comme construction de base N0 V N1 Prép N2, mais également la construction N0 V N1 et la distribution N1 = : de V2-inf W, ce qui est traduit au format Lefff par 2 entrées avec les cadres de sous-catégorisation suivants :

<sup>4.</sup> Nous avons réalisé ce travail en collaboration avec Eric de La Clergerie en 2011.

<sup>5.</sup> Une forme suspecte doit aussi avoir tendance à apparaître seule dans de telles phrases ou en cooccurrence avec des formes qui ne sont pas (trop) suspectes à l'échelle du corpus entier. On trouvera le détail du modèle sous-jacent dans Sagot et de La Clergerie (2008); il s'exprime sous forme d'une paire d'équations mutuellement récursives reflétant le niveau local des phrases et le niveau global du corpus. L'algorithme de résolution est un algorithme de point fixe.

```
<Suj:cln|scompl|sn|de-sinf,Obj:sn|scompl|de-sinf|cla,Obl:pour-sn|sn>
<Suj:cln|scompl|sn,Obj:sn|scompl|cla>
```

au lieu d'avoir un seul même cadre avec le deuxième complément facultatif.

Les autres suspects dans LGLex sont seulement des erreurs ou des phrases complexes :

- monder qui n'est pas un verbe dans 3 phrases semblables à Bonjour tout\_le\_monde;
- accroître dans une phrase sans sujet : Accroître  $leurs\ parts\ de\ march\'e$  ;
- accroître employé comme adjectif dans les promesses d'autonomie accrue;
- soupçonner dans Celui qui ne ferait qu'errer autour de la royale abbaye, n'en soupçonnerait nullement la beauté réelle, car le sujet est complexe;
- impliquer employé dans la phrase complexe : Tous les agonistes dopaminergiques stimulent les récepteurs D2, initialement considérés comme étant seuls impliqués dans les effets moteurs de la dopamine.

Les techniques de fouille d'erreurs permettant de comparer (dans un sens ou l'autre) les verbes de deux lexiques sont un moyen de repérer plus rapidement ces entrées. Il importe donc de refaire cette expérience sur un corpus plus volumineux afin de détecter le plus grand nombre de verbes manquants dans les tables ou y figurant sans être codés (codage  $\sim$ ), afin de compléter les tables; mais également de trouver les constructions manquantes pour certains verbes. Nous nous attendons à ce que la plupart des constructions manquantes proviennent du processus de conversion, mais certaines proviendront peut-être d'erreurs se situant dans les tables du Lexique-Grammaire. De telles considérations permettrait d'améliorer ces dernières.

# 10.4 Évaluation manuelle

Même si les résultats sont bons si l'on se compare à l'état de l'art, il importe d'évaluer la qualité des analyses. Pour cela nous avons vérifié manuellement, pour quelques phrases extraites du corpus de référence de la première campagne Passage, si les entrées trouvées lors de l'analyse avec FRMG correspondent à celles attendues d'après la classification du Lexique-Grammaire. Bien entendu, cela ne dépend pas que du contenu dans les tables mais également du fonctionnement de FRMG, notamment de son module de désambiguïsation, ce qui oblige à être prudent envers les résultats (en plus des précautions déjà citées):

- différentes entrées peuvent avoir la même construction et ne sont donc pas détectables;
- les compléments circonstanciel ne sont pas décrits dans les tables, donc tout complément peut être pris pour un complément circonstanciel et donc être accepté même s'il ne figure pas dans le cadre de sous-catégorisation de l'entrée;
- nous évaluons après désambiguïsation, alors que dans certains cas la bonne table figure en mode non désambiguïsé, parmi un grand nombre d'autres tables, ce qui résulte plus difficile à évaluer. Le module de désambiguïsation de FRMG basé sur des heuristiques ne donne pas forcément la priorité aux bonnes tables.

Notons que les tables de noms prédicatifs ne font pas partie de cette évaluation puisque les seuls noms prédicatifs pris en compte par FRMG sont ceux n'ayant pas de

déterminant, et ils sont rares dans les corpus.

Nous avons extrait les premières phrases de deux sous-corpus (general\_lemonde et general\_elda), en ne gardant que celles ayant donné une analyse avec FRMG (en mode désambiguïsé) et contenant au moins un verbe<sup>6</sup>. Nous avons indiqué en gras les identifiants des verbes trouvés dans le lexique LGLex, en sachant que les verbes trouvés grâce au Lefff n'ont pas été répertoriés (il s'agit notamment des auxiliaires être et avoir). Nous avons regroupé les assignations correctes d'entrées codées dans les tables, les assignations incorrectes d'entrées codées dans les tables et les assignations incorrectes d'entrées non codées dans les tables. Notre expérience c'est limitée aux 33 premiers verbes de chaque sous-corpus (sans compter ceux qui ont été identifiés comme verbe mais qui n'en sont pas) et a été validée par des linguistes différents pour chacun des sous-corpus.

La Tab. 10.2 contient les 21 premières phrases du sous-corpus general\_lemonde ayant donné une analyse avec FRMG. Ces phrases contiennent 33 verbes <sup>7</sup> reconnus grâce aux tables. Nous donnons aux Tab. 10.3 à 10.5 les résultats validés par Eric Laporte.

Au total, 48% des assignations d'entrées sont correctes pour le sous-corpus general\_lemonde, soit 59% si l'on ne tient pas compte des entrées non codées dans les tables.

La Tab. 10.6 contient les 14 premières phrases du sous-corpus general\_elda ayant donné une analyse avec FRMG. Ces phrases contiennent 33 verbes <sup>8</sup> reconnus grâce aux tables. Nous donnons aux Tab. 10.7 à 10.9 les résultats validés par Christian Leclère et Takuya Namakura.

Au total, 33% des assignations d'entrées sont correctes pour le sous-corpus general\_elda, soit 42% si l'on ne tient pas compte des entrées non codées dans les tables.

Nous montrons à la Tab. 10.10 comment le taux de succès dans les deux sous-corpus varie en fonction du nombre d'entrées de chaque verbe dans la classification du Lexique-Grammaire. Par exemple, le verbe *utiliser* ne contient qu'une seule entrée alors que le verbe *être* en contient 27, ce qui produit beaucoup plus d'ambiguïtés.

Le faible nombre de phrases évaluées manuellement ne permet pas d'en conclure davantage. Cette évaluation pourrait être en effet poursuivie afin d'obtenir des résultats plus représentatifs. Malheureusement, cette validation n'est possible que par des linguistes connaissant bien les tables du Lexique-Grammaire.

<sup>6.</sup> Notons que dans le sous-corpus general\_elda, une phrase peut être composée d'une listes à tirets avec plusieurs phrases. FRMG analyse uniquement la première phrase correspondant au premier tiret, puisqu'il s'agit d'une analyse phrase par phrase. Pour plus de lisibilité, nous n'avons gardé que cette première phrase dans les listes à tirets, les autres n'ayant pas été analysées.

<sup>7.</sup> En réalité, 35 verbes, mais nous mettons de côté l'adjectif mesurées (phrase 159), ainsi que le nom président (phrase 7.1).

<sup>8.</sup> En réalité, 34 verbes, mais nous mettons de côté l'adjectif appropriées (phrase 48).

- 1 Depuis quelques semaines, les rapports entre les deux camps se dégradent\_\_\_V\_32PL\_46\_\_1.
- 2 Le gouvernement intérimaire a visiblement décidé\_\_\_V\_8\_41\_\_1 d'asphyxier\_\_\_V\_32H\_48\_\_1 économiquement le " Taylorland ", en imposant\_\_\_V\_37M1\_111\_\_1 un embargo total sur les marchandises à destination des zones sous contrôle du FNPL et en remplaçant\_\_\_V\_32H\_592\_\_1 les coupures de 5 dollars libériens , les plus utilisés\_\_\_V\_11\_225\_\_1 , par de nouveaux billets .
- 4 Pendant ce temps, le drame des Libériens se poursuit\_\_\_V\_37M1\_159\_\_1.
- $7.1 " Vous venez\_\_V\_2\_190\_1 nourrir\_\_V\_37M1\_140\_2 les Kranhs " ( les membres de l'ethnie du défunt président\_\_V\_32R3\_692\_1 Samuel Doe ) lui a lancé\_\_V\_9\_236\_1 le petit seigneur de guerre qui régnait\_\_V\_35R\_372\_1 sur son " check point " , son barrage routier .$
- 8 Dans cette région , les enfants , les cheveux décolorés et le ventre ballonné , souffrent\_\_V\_35R\_438\_1 de kwashiorkor .
- $9 \ \mathit{Ils manquent}_{--}V_{-}34L0_{-}61_{--}1 \ \mathit{de prot\'eines}$  .
- **54** Boutros Boutros-Ghali , effectuera\_\_\_V\_32R2\_170\_\_1 son premier voyage ès qualités à l'étranger en se rendant\_\_\_V\_2\_146\_\_1 le 10 janvier à Paris , puis le 13 janvier à Londres .
- 55 Ce premier déplacement n'  $a_{--}V_{-}38R_{-}31_{--}1$  rien d' officiel , a précisé $_{--}V_{-}9_{-}295_{--}1$  son porte-parole , en ajoutant $_{--}V_{-}10_{-}9_{--}1$  qu' il ne s' agissait que d' une visite de travail .
- **56** La France a été $\_\_V\_33\_60\_1$  l'un des principaux artisans au sein du Conseil de sécurité de l'élection de M.
- **57** Boutros-Ghali , et Londres préside\_\_\_V\_32R3\_692\_1 pendant le mois de janvier le Conseil de sécurité . \_
- 58 En France, 19 % des femmes actives ont été victimes de harcèlement sexuel sur leur lieu de travail.
- **59** C' est\_\_V\_5\_63\_\_1 ce que révèle\_V\_32H\_610\_\_1 un sondage rendu\_\_V\_39\_79\_\_\_1 public , mardi 7 janvier , par Mme Véronique Neiertz , secrétaire d' Etat aux droits des femmes et à la vie quotidienne .
- **62** Les victimes se plaignent\_\_V\_13\_111\_\_2 en premier de " propos et gestes douteux " ( 63~% ) , mais aussi d' " avances répétées malgré un refus " ( 60~% ) .
- **63** Dans 48 % des cas , elles parlent\_\_\_ $V_5_93_1$  d'" un climat d'ensemble déplaisant " , et 12 % des avances sont assorties d'un chantage .
- **79** *Il s' élève\_***38LD\_100\_\_1** à 9 534 .
- $\bf 81\ L$  ' effort de sécurité routière ne s' en pour suit\_\_\_V\_6\_346\_\_1 pas moins .
- $\mathbf{83}\ \mathit{Georges}\ \mathit{Sarre}\ ,\ \mathit{secr\'etaire}\ \mathit{d'Etat}\ \mathit{charg\'e}\_\_V\_\mathbf{37M6}\_\mathbf{63}\_\_\mathbf{1}\ \mathit{des}\ \mathit{transports}\ \mathit{routiers}\ \mathit{et}\ \mathit{fluviaux}$
- 157 Les constructeurs français s'attendent\_\_\_V\_6\_36\_\_1 à une croissance de 2 % à 3 % en 1992 159 Le CCFA (Comité des constructeurs français d'automobiles) a publié\_\_\_V\_6\_375\_\_1, mardi
- 7 janvier, des perspectives 1992 très mesurées\_\_V\_32A\_84\_\_1.

  160 L'organisme professionnel prévoit\_\_V\_6\_359\_\_1 une croissance de 2 % à 3 % des ventes de voitures particulières en France pour l'ensemble de l'année 1992.
- **161** Le marché , qui a enregistré\_\_\_V\_6\_166\_\_1 en 1991 un repli de 12 % , atteindrait\_\_\_V\_38L1\_10\_\_1 ainsi les 2 100 000 unités .

Table 10.2: Extrait du sous-corpus general\_lemonde avec les identifiants des verbes analysés

```
décider (phrase 2) : table 8 (Ceci décidera de que ce Luc parte)
imposer (phrase 2): table 37M1 (On impose les revenus des citoyens d'une lourde taxe)
utiliser (phrase 2): table 11 (Max utilise (ses talents+Ida) à faire la cuisine)
venir (phrase 7.1) : table 2 (Max vient chez Luc déjeuner)
nourrir (phrase 7.1) : table 37M1 (Max nourrit Léa de riz)
lancer (phrase 7.1): table 9 Max lance à Ida qu'il va partir)
régner (phrase 7.1) : table 35R (Max règne sur la cuisine)
souffrir (phrase 8): table 35R (Cet appareil souffre d'un défaut de fabrication)
manquer (phrase 9): table 34L0 (Le sel manque dans ce plat)
effectuer (phrase 54): table 32R2 (Cette machine effectue les calculs)
se rendre (phrase 54) : table 2 (Max s'est rendu à Paris chercher du travail)
préciser (phrase 55) : table 9 (Max a précisé à Luc qu'il faudrait travailler)
rendre (phrase 59): table 39 (Ses diplômes rendent Max un candidat valable)
publier (phrase 159) : table 6 (Max a publié que le gouvernement était corrompu)
prévoir (phrase 160) : table 6 (Max a prévu que Léa arriverait en retard)
atteindre (phrase 161) : table 38L1 (Max atteint (le sommet+la bouteille))
```

Table 10.3: Assignations correctes des entrées codées dans les tables

```
Table erronée donnée par FRMG \rightarrow Table attendue
se dégrader (phrase 1) : table 32PL (Max a dégradé les couleurs) \rightarrow table 32C (Les enfants ont
dégradé le matériel) : pas de colonne codant l'entrée pronominale
asphyxier (phrase 2): table 32H (Ces qaz ont asphyxié le bébé) \rightarrow table 4 (Ce type d'éducation
asphyxie les enfants)
remplacer (phrase 2): table 32H (Cet interne remplace le médecin) \rightarrow table 38R (Max a remplacé
le déjeuner par une marche)
ajouter (phrase 55): table 10 (Max a ajouté au dossier que l'accord avait été respecté) \rightarrow table 9
(Max a ajouté à Paul qu'il n'y aurait pas de réunion) : ambigu car le complément qui permettrait
de faire la distinction entre la table 9 et 10 est absent
être (phrase 56): table 33 (Cette voiture est à Max) \rightarrow table 32NM, entrée 61 (Max est un idiot)
r\'{e}v\'{e}ler (phrase 59) : table 32H (Ce livre a r\'{e}v\'{e}l\'{e} (cette artiste+Max) au public) \rightarrow table 9 (Max
a révélé à Luc que Léa était partie)
se plaindre (phrase 62) : table 13 (Max plaint Luc de ce qu'il soit si malheureux) \rightarrow table 15 (Max
se plaint amèrement à Luc de ce que tout est dérangé)
s' élever (phrase 79) : table 38LD (La crue a élevé le niveau (à la cote 23+de cinquante cm)) \rightarrow
table 33 (La facture s'élève à 1000 francs)
charger (phrase 83) : table 37M6, entrée 63 (Max charge le camion d'oranges) → table 13, entrée
23 (Max charge Luc de ce que tout soit en ordre)
s' attendre (phrase 157): table 6 (pas pronominal) \rightarrow table 7 (Max s'attend à ce qu'Ida parte)
```

Table 10.4: Assignations incorrectes d'entrées codées dans les tables

```
Table erronée donnée par FRMG \rightarrow Table ou autre entrée attendue se poursuivre (phrase 4) : table 37M1 (Max poursuit Ida de ses (sarcasmes+assiduités)) \rightarrow pas d'entrée pour ce verbe avoir (phrase 55) : table 38R (Paul a eu Luc comme secrétaire) \rightarrow verbe support du nom officiel, non codé dans les tables présider (phrase 57) : table 32R3, entrée 692 (Max préside (le banquet+à table)) \rightarrow table 32R3, entrée 693 (Max préside cette association) : l'entrée n'est pas codée (codage \sim) parler (phrase 63) : table 5 (Ceci parle pour Paul) \rightarrow table 1 (Max parle de prendre sa retraite) : l'entrée n'est pas codée (codage \sim) être (phrase 59) : table 5 (Il est dans les intentions de Max que Léa vienne) \rightarrow ne correspond à aucune des entrées des tables : c'est une pseudo-clivée inversée se poursuivre (phrase 81) : table 6 (Max poursuivit que la situation était grave et qu'il fallait agir) \rightarrow pas d'entrée pour ce verbe enregistrer (phrase 161) : table 6 (Luc a enregistré que Luc était passé) \rightarrow table 32NM (On a enregistré une hausse) : l'entrée n'est pas codée (codage \sim)
```

Table 10.5: Assignations incorrectes d'entrées non codées dans les tables

Remarquons que pour les assignations incorrectes d'entrées codées dans les tables, l'erreur peut aussi bien venir de l'analyseur que des tables. Une étude plus poussée permettrait de le définir. En revanche, pour les assignations incorrectes d'entrées non codées dans les tables, cela montre que le codage de certaines entrées a besoin d'être complété.

- **2** A quoi servent\_\_\_V\_18\_16\_\_1 les ressources linguistiques?
- 7 Les ressources linguistiques sont utilisées...V\_11\_225\_\_1 pour évaluer...V\_6\_197\_\_1 les systèmes de traitement du langage oral ou écrit existants et établir...V\_39\_34\_\_1 des comparatifs entre systèmes .
- 8 Les évaluations sont particulièrement importantes lorsqu' il s' agit de noter $\_\_V_10_147_1$  les évolutions et progrès d' un système .
- 9 Des secteurs comme ceux des télécommunications , de l'information et de la communication , des affaires internationales ( et multilingues ) , de l'éducation ou de l'apprentissage sont\_ $V_5_63_1$  en contact direct et permanent avec les langues , pour la traduction , la terminologie , la reconnaissance de texte ou de la parole , l'extraction , la recherche d'information , etc .
- 10 L'utilisation et l'exploitation des ressources linguistiques , intégrées\_\_\_V\_38LD\_201\_\_1 ou pas dans des produits spécifiques , apportent\_\_\_V\_10\_15\_\_1 aux organisations et entreprises qui évoluent\_\_\_V\_35R\_197\_\_1 dans ces secteurs de nombreux avantages et bénéfices .
- 11.1  $Augmenter_{--}V_{-}36R_{-}16_{--}1$  la rentabilit'e .
- 11.2  $Am\'eliorer_{--}V_{-}4_{-}33_{--}1$  les services et l'information .
- 41 ELRA participe\_\_\_V\_33\_107\_1 ainsi pleinement au développement et à la croissance du marché et du domaine de l'Ingénierie Linguistique .
- **48** L'activité d'évaluation chez ELRA et ELDA a débuté\_\_\_V\_31H\_151\_\_1 en fournissant\_\_\_V\_33\_68\_\_1 les ressources linguistiques appropriées\_\_\_V\_36R\_11\_\_1 pour les tests d'évaluation (Amaryllis, Aurora, CLEF).
- **50** L'évaluation est... $V_33_61_{-1}$  un facteur de premier plan dans le domaine de l'ingénierie linguistique, et ce à différents niveaux.
- 51 L'évaluation permet\_\_\_V\_9\_283\_\_1 aux équipes de R & D de valider\_\_\_V\_32RA\_459\_\_2 leurs recherches et d'assurer\_\_\_V\_32RA\_58\_\_1 ainsi le développement des systèmes , en constante progression .
- 54 Les campagnes d'évaluation contribuent.... $V_-7_-37_-1$  également à la production de données de test ou d'entraînement de très bonne qualité , de méthodologies , métriques et protocoles , qui peuvent.... $V_-1_-88_-1$  ensemble être mis.... $V_-38LR_-158_-1$  à disposition sous la forme de 'lots pour l'évaluation', et distribués.... $V_-32R3_-304_-1$  comme le sont.... $V_-35R_-195_-1$  les ressources linguistiques habituelles .
- **56** L' activité d' évaluation peut\_\_\_ $V_1_92_1$  être menée\_\_ $V_3_91$  à différents niveaux :
- $\bf 56.1 \textit{Evaluation des technologies (pour trouver\_\_V\_11\_122\_\_1 \textit{les solutions aux problèmes clairement définis )}$
- 57 Les projets d'évaluation auxquels ELRA/ELDA participe\_\_\_V\_33\_106\_\_1 à l'heure actuelle  $sont_{--}V_31H_225_{-}1$ : Technolangue/EVALDA

Table 10.6: Extrait du sous-corpus general\_elda avec les identifiants des verbes analysés

```
utiliser (phrase 7): table 11 (Max utilise (ses talents+Ida) à faire la cuisine)
évaluer (phrase 7): table 6 (Max évalue si l'opération est rentable ou non)
intégrer (phrase 10): table 38LD (Jo a intégré cet appareil dans son système)
évoluer (phrase 10): table 35R (La maladie évolue (E+vers) un mieux)
permettre (phrase 51): table 9, entrée 283 (Ceci permet à Luc qu'il ait ce poste)
valider (phrase 51): table 32RA (Max a validé le document (E+d'un tampon))
assurer (phrase 51): table 32RA (Max assure sa prise)
permettre (phrase 52): table 9, entrée 283 (Ceci permet à Luc qu'il ait ce poste)
orienter (phrase 52): table 35R (Max s'oriente (sur+d'après) l'étoile polaire)
contribuer (phrase 54): table 7 (Max contribue à ce que tout soit en ordre)
pouvoir (phrase 56): table 1 entrée 88 (Max pourrait réussir, qui sait?)
```

Table 10.7: Assignations correctes d'entrées codées dans les tables

```
Table erronée donnée par FRMG \rightarrow Table attendue
servir (phrase 2): table 18 (Qu'Ida soit partie sert de prétexte à Max pour la congédier) \rightarrow table
16 (Ce torchon sert à Max à nettoyer les vitres) ou table 14 (Cette histoire a servi pour Max à ce
qu'il soit élu)
établir (phrase 7) : table 39 (Max a établi son fils (E+comme) notaire) \rightarrow table 32A (Max a établi
une liste de suspects)
noter (phrase 8): table 10 (Max note sur son agenda (qu'il aille+d'aller) chez le coiffeur) \rightarrow table
6 (Max note (que Léa est absente+son impatience))
am\'eliorer (phrase 11.2): table 4 (Qu'il ait travaillé am\'eliore Max) \rightarrow table 32RA (Max am\'eliore
le potage d'un peu de poivre)
participer (phrase 41) : table 33, entrée 107 (Je participe à votre (douleur+joie)) → table 33, entrée
108 (Max participe (au jeu+aux délibérations)) : c'est uniquement la construction de base NO V à
N1 qui permet de les reconnaître, sans les distinguer
d\acute{e}buter (phrase 48): table 31H (Max d\acute{e}bute dans (la vie+le monde)) \rightarrow table 38R (Max d\acute{e}bute
son repas par un oeuf)
fournir (phrase 48): table 33 (Sa famille fournit aux dépenses de Bob) \rightarrow table 36DT (Max fournit
du vin à Luc)
être (phrase 50): table 33 (Cette voiture est à Max) \rightarrow table 32NM, entrée 62 (Max est un idiot)
identifier (phrase 52): table 32R3 (Max a identifié le corps) \rightarrow table 6 (Max identifiera si le tableau
est vrai ou non)
développer (phrase 52): table 32R3, entrée 209 (Max a développé ce produit) \rightarrow table 32R2 (Max
développe (ses ventes+son usine))
aboutir (phrase 52): table 35LD (Max aboutit au village) → table 14 (Tes ordres ont abouti pour
Luc à ce qu'il se révolte)
pouvoir (phrase 54) : table 1, entrée 88 (Max pourrait réussir, qui sait?) → table 1, entrée 87
(Max peut passer entre les barreaux)
distribuer (phrase 54) : table 32R3 (Le metteur en scène a distribué (la pièce+le film)) → table
36DT (Max distribue de l'argent à ses amis)
participer (phrase 57) : table 33, entrée 106 (Ces colonnes participent à la beauté de l'édifice) →
table 33, entrée 108 (Max participe (au jeu+aux délibérations))
être (phrase 57) : table 31H (Max en est) \rightarrow table 32NM, entrée 62 (Max est un idiot)
```

Table 10.8: Assignations incorrectes d'entrées codées dans les tables

#### Table erronée donnée par FRMG $\rightarrow$ Table ou autre entrée attendue

être (phrase 9) : table 5 (Il est dans les intentions de Max que Léa vienne)  $\rightarrow$  verbe support être en, non codé dans les tables

apporter (phrase 10) : table 10 (Cette remarque a apporté dans la discussion que tout devait être revu)  $\rightarrow$  table 36DT (Paul apporte des fleurs à Marie) : l'entrée n'est pas codée (codage  $\sim$ )

augmenter (phrase 11.1) : table 36R (Max a augmenté le nombre des lits à six)  $\rightarrow$  table 37M4 (Max a augmenté son rapport de trois pages) : l'entrée n'est pas codée (codage  $\sim$ )

mettre (phrase 54) : table 38LR (Max met cette ville dans le Sud)  $\rightarrow$  expression figée mettre à disposition, non codée dans les tables

être (phrase 54) : table 35R, entrée 195 ( $Max\ en\ est\ de\ cent\ francs\ dans\ cette\ histoire$ )  $\to$  être est auxiliaire de distribuer : il devrait être reconnu par le Lefff mais il est difficile à reconnaître dans cette phrase

mener (phrase 56) : table 3 (Max mène Ida se faire coiffer)  $\rightarrow$  verbe support du nom activité, non codé dans les tables

trouver (phrase 56.1) : table 11, entrée 122 ( $Max\ a\ trouvé\ du\ plaisir\ à\ faire\ cela$ )  $\to$  table 32A ( $Max\ a\ trouvé\ un\ (nouveau\ médicament+algorithme)$ ) : l'entrée n'est pas codée (codage  $\sim$ )

Table 10.9: Assignations incorrectes d'entrées non codées dans les tables

| Nombre d'entrées dans les tables | 1    | 2   | 3   | 4   | 5   | 6 à 27 | Total |
|----------------------------------|------|-----|-----|-----|-----|--------|-------|
| Taux de succès                   | 100% | 50% | 67% | 50% | 10% | 32%    | 41%   |
| Taux de succès parmi les entrées | 100% | 50% | 75% | 50% | 17% | 50%    | 52%   |
| codées dans les tables           |      |     |     |     |     |        |       |

Table 10.10: Taux de succès dans les deux sous-corpus en fonction du nombre d'entrées de chaque verbe

Pour finir, nous avons testé quelques noms prédicatifs sans déterminant, pour vérifier s'ils étaient bien reconnus par FRMG. Les noms prédicatifs sans déterminant ne représentent qu'une infime partie des entrées du Lexique-Grammaire; en effet, uniquement 241 entrées acceptent la propriété Det = : <E> ou ont la valeur <E> dans les colonnes autre Det ou Det figé. Nous avons testé quelques phrases non tirées de corpus <sup>9</sup> dont les résultats sont à la Tab. 10.11.

| Mode désambiguïsé   | Autres possibilités en mode non désambiguïsé                       |
|---|--|
| Assignation correctes d'entrées :                                   |  |
| Max a soinN_an01_1202 de ses affaires                               |  |
| Max a hâteN_ape3_862 de partir                                      |  |
| Max fait abusN_f8_11 de cette règle auprès                          |  |
| de Marie  |  |
| Max fait honneurN_fnan_1161 à Marie                                 |  |
| Max fait allusionN _fnpn_31 à cette série                           |  |
| $Max\ donne\ abri\_\_N_dr1_1_1\ à\ Marie$                           |  |
| Assignation d'entrées codées dans plusieurs                         |  |
| tables:   |  |
| Max a accèsN_ape2_1_2 à la sortie                                   | Max a accèsN_ana_772 à la sortie                                   |
| Max a droitN_ana_772 à des sous                                     | Max a droitN_ape2_202 à des sous                                   |
|   | Max a droitN_ape2_212 à des sous                                   |
|   | $Max \ a \ droit\_\_N_ape2\_22\_\_2 \ \grave{a} \ des \ sous$      |
| Assignation d'entrées verbales de la table 32NM :                   |  |
| La bombe a faitV_32NM_651 explosion                                 | $La\ bombe\ a\ fait\ explosion\_\_N_f1b_19\_1$                     |
| $Max \ a_{}V_{-}32NM_{-}12_{}1 \ mal \ \grave{a} \ la \ t\hat{e}te$ | $Max \ a \ mal\_\_N\_anml\_198\_\_1 \ \grave{a} \ la \ t\hat{e}te$ |
| Assignation d'entrées du Lefff:                                     |  |
| Max fait honte à Marie  | $Max\ fait\ honte\_\_N_f41_8\_1\ \grave{a}\ Marie$                 |
| La porte fait obstacle au passage                                   | La porte fait obstacleN_fs2_711 au passage                         |

Table 10.11: Phrases avec les identifiants des noms (ou verbes) analysés

Nous constatons que, dans l'ensemble, les assignations d'entrées sont correctes. Certaines entrées sont codées dans plusieurs tables (ici APE2 et ANA) et donc sont reconnues par une seule arbitrairement lors de la désambiguïsation. D'autres ne sont pas choisies lors de la désambiguïsation à cause des verbes de la table 32NM. Enfin, certaines sont directement reconnues par le Lefff, puisque nous n'avons pas exclu les quelques noms prédicatifs que contient le Lefff.

#### 10.5 Conclusion

Nous avons développé une méthodologie et un outil permettant de convertir la version textuelle des tables du Lexique-Grammaire en un lexique pour le TAL utilisant le forma-

<sup>9.</sup> En faisant une recherche dans les deux sous-corpus general\_lemonde et general\_elda, la seule phrase contenant un des noms prédicatifs cités à la Tab. 10.11 est :

**<sup>2222</sup>** Aucun des commentaires publiés n' a fait allusion\_\_\_N \_fnpn\_3\_1 à cet aspect des relations entre Paris et Pékin .

Cela explique pourquoi dans les 35 phrases analysées ci-dessus aucun nom prédicatif sans déterminant n'a été trouvé.

lisme lexical du Lefff, ce qui permet de l'utiliser à peu près immédiatement par l'analyseur syntaxique FRMG. La pertinence du lexique obtenu a été validée par son utilisation pour l'analyse syntaxique automatique du corpus d'évaluation de la campagne Passage. En effet, pour un lexique de bonne qualité comme les tables du Lexique-Grammaire, les résultats obtenus sont bons.

Ce travail nous a permis d'identifier un certain nombre de problèmes dans les données de départ (tables et table des classes), mais il nous a également conduit à un certain nombre de simplifications et d'approximations dans le processus de conversion. Il subsiste d'importantes possibilités d'améliorations, qui pourraient permettre de construire un lexique syntaxique pour le TAL à partir des tables du Lexique-Grammaire, avec en perspective l'amélioration de la qualité des outils et des ressources existants. Ceci par fusion avec d'autres ressources lexicales, par exemple, ou par intégration dans un analyseur syntaxique opérationnel.

# Chapitre 10 Intégration dans frmg et évaluation

# 11

# Conclusion et perspectives

Nous dressons un bilan du travail effectué sur les tables du Lexique-Grammaire du français afin de les rendre exploitables dans des analyseurs syntaxiques dans la section 11.1. Puis, nous évoquons en 11.2.1 l'extension de ce travail à d'autres langues, telles que le grec, afin de construire un lexique syntaxique à partir des tables du Lexique-Grammaire du grec. Enfin, nous terminons par quelques pistes afin d'améliorer le lexique LGLex-Lefff du français et son intégration dans FRMG en 11.2.2.

## 11.1 Conclusion

Les tables du Lexique-Grammaire du français constituent une grande base de données lexicales, syntaxiques et sémantiques. Diverses incohérences et carences empêchaient leur exploitation automatique directe dans des outils de TAL :

- des intitulés de colonnes qui différaient d'une table à l'autre, bien que dénotant la même propriété linguistique;
- des intitulés de colonnes qui ne dénotaient pas la même propriété d'une table à l'autre;
- des intitulés de colonnes qui laissaient implicites des informations, pourtant nécessaires à leur exploitation automatique;
- des informations importantes qui n'étaient pas représentées, car elles étaient considérées comme implicites pour une table donnée.

Pour que les tables forment un tout cohérent, nous avons réalisé un ensemble de modifications :

- nouvelles tables numérisées et corrigées pour les noms prédicatifs et les expressions figées;
- renommage dans toutes les tables d'un grand nombre de propriétés;

- création de la table des classes pour chaque catégorie regroupant toutes les propriétés;
- définition des propriétés définitoires vraies pour toutes les entrées d'une table, ainsi que leur codage dans la table des classes concernée;
- codage de propriétés dans les tables et dans la table des classes;
- ajout d'entrées dans les tables de verbes et déplacement de certaines entrées;
- ajout d'exemples pour les tables de noms;
- documentation de toutes les propriétés des tables de verbes;
- définition formelle de toutes les tables de verbes;
- arbre de classement permettant de déterminer à quelle classe appartient une entrée verbale donnée.

De plus, nous avons décrit tous les changements que nous avons réalisé pour définir les constructions de base pour chaque classe dans toutes les catégories (verbes distributionnels, noms prédicatifs, expressions figées et adverbes).

Nous avons converti les tables au format LGLex pour l'ensemble des catégories grâce à l'outil LGExtract. Cet outil, associé à un script et à la table des classes, permet de créer un lexique au format XML ou texte. Ce script décrit les opérations à effectuer pour chaque propriété, ce qui permet de définir une seule fois chaque intitulé. Ce lexique manipule les mêmes concepts que ceux des tables, il est donc utilisable par toute personne voulant utiliser les tables sans devoir lire des tables Excel, qui ne servent qu'à la lisibilité lors de leur visualisation.

Enfin, nous avons converti les tables des verbes et des noms prédicatifs au format Alexina, le format du lexique Lefff, afin de pouvoir les utiliser directement dans l'analyseur syntaxique FRMG. Pour cela, nous avons développé une méthodologie et un outil permettant de convertir la version textuelle des tables du Lexique-Grammaire en un lexique pour le TAL utilisant le formalisme lexical du Lefff, ce qui le rend utilisable par l'analyseur syntaxique FRMG.

De plus, ce travail de conversion nous a permis d'identifier un certain nombre de problèmes dans les données de départ (tables et table des classes), que nous avons pu corriger.

La pertinence du lexique obtenu a été validée par son utilisation pour l'analyse syntaxique automatique du corpus de référence de la première campagne Passage. En effet, nous avons évalué l'analyseur FRMG avec le lexique que nous avons créé (*LGLex-Lefff*), tout en conservant le *Lefff*, hormis les entrées verbales. Nous en avons conclu que les tables de verbes permettent d'obtenir d'aussi bons résultats que l'état de l'art.

# 11.2 Perspectives

# 11.2.1 Application aux tables du grec

En excluant le français, le grec est la langue pour laquelle il existe le plus de tables du Lexique-Grammaire. C'est pourquoi nous envisageons leur conversion en un lexique

syntaxique (Ioannidou et Kyriacopoulou, 2010).

Les tables du Lexique-Grammaire du grec sont en cours d'élaboration et constituent la principale source d'informations lexicales, syntaxiques et sémantiques de la langue. Il existe aujourd'hui 17 tables de verbes simples (Kyriacopoulou, 2010), 7 de noms prédicatifs (Sfetsiou, 2007) et 16 tables d'adverbes (semi-)figés (Voyatzi, 2006; Voyatzi et Kakoyianni-Doa, 2010).

Les tables verbales concernent les verbes transitifs non locatifs (tables 32GA, 32GD, 32GC, 32GCL, 32GCV, 32GH, 32GNM, 32GPL, 32GRA), les tables à complétives (4G, 6G et 9G) ainsi que les verbes transitifs locatifs (tables 38GL, 38GLS, 38GLD, 38GLH, 38GLR). Les tables des noms prédicatifs concernent les noms à verbe support  $\kappa \acute{\alpha} \nu \omega$ , faire en français (tables FN1, FN2, FNPN, FNAN-hum, FNANhum, FNANlieu, FND-NAN). Les tables d'adverbes (semi-)figés sont parfaitement analogues aux 16 tables des adverbes figés du français (Gross, 1990). Elles portent les mêmes noms que celles du français, précédés de la lettre G pour «grec» (tables GPADV, GPC, GPAC, GPCA, GPCONJ, GPCPC, GPCDC, GPCONJ, GPCDN, GPCPN, GPV, GPF, GPECO, GPVCO, GPPCO, GPJC).

Les tables verbales comptent 3 969 entrées, les tables de noms prédicatifs 900 entrées, et les tables d'adverbes (semi-)figés 5 080 entrées.

La démarche générale est la suivante :

- collecter toutes les tables du grec;
- créer une table des classes par catégorie grammaticale, afin de rendre cohérent l'ensemble des tables et d'y faire figurer les propriétés définitoires;
- créer un script par catégorie grammaticale en interprétant chaque intitulé, afin de convertir les tables au format LGLex;
- modifier lglex2ilex.pl en tenant compte des différences dans la langue grecque, afin de convertir les tables au format Alexina, le format du lexique Lefff.

Enfin, si l'on souhaite utiliser ce lexique syntaxique dans un analyseur syntaxique, il faut adapter la méta-grammaire du français à celle du grec, comme cela a été fait pour l'espagnol (Fernández González, 2010).

Nous avons déjà participé à l'harmonisation des tables du grec avec la collaboration de K. Ioannidou, dans le but de constituer la table des classes des verbes grecs, incluant toutes les propriétés définitoires <sup>1</sup>. Lors de la création de la table des classes, nous avons

32GCV: N0 V N1, avec N0 Vsup N1 Prep V-n

 $32\mathrm{GH}: \mathsf{N0} \ \mathsf{V} \ \mathsf{N1}, \ \mathrm{avec} \ \mathsf{N1} =: \mathsf{Nhum} \ 32\mathrm{GNM}: \mathsf{N0} \ \mathsf{V} \ \mathsf{N1}, \ \mathrm{avec} \ \mathsf{N1} =: \mathsf{N-hum} \ 32\mathrm{GPL}: \mathsf{N0} \ \mathsf{V} \ \mathsf{N1}, \ \mathrm{avec} \ \mathsf{N1} =: \mathsf{Npl} \ \mathsf{obl}$ 

 $32\mathrm{GRA}: \mathsf{N0}\;\mathsf{V}\;\mathsf{N1},\;\mathrm{avec}\;\mathsf{N0}\;\mathsf{Vsup}\;\mathsf{N1}\;\mathsf{V-adjaccusatif}\; \textit{[\'equivalent \'a}\;\mathsf{V-adj}\textit{]}$ 

4G : N0 V N1, avec une complétive en N0

<sup>1.</sup> Nous avons défini les propriétés définitoires vraies pour l'ensemble des entrées de chaque tables, incluant la construction de base, comme suit :

 $<sup>32\</sup>mathrm{GA}: \mathrm{N0}\ \mathrm{V}\ \mathrm{N1},\ \mathrm{avec}\ \mathrm{N1}\ \mathrm{apparition}$   $32\mathrm{GD}: \mathrm{N0}\ \mathrm{V}\ \mathrm{N1},\ \mathrm{avec}\ \mathrm{N1}\ \mathrm{disparition}$   $32\mathrm{GC}: \mathrm{N0}\ \mathrm{V}\ \mathrm{N1},\ \mathrm{avec}\ \mathrm{N1}=: \mathrm{Nconc}$   $32\mathrm{GCL}: \mathrm{N0}\ \mathrm{V}\ \mathrm{N1},\ \mathrm{avec}\ \mathrm{N1}=: \mathrm{Npc}$ 

rencontré divers types d'ambiguïtés formelles.

À part des problèmes typographiques divers (présence ou non d'espaces, alternance de lettres majuscules et minuscules, ou de caractères grecs et latins), certains intitulés exprimant la même notion linguistique sont notés avec des symboles différents (par exemple, N1 = : Nplur obl et N1 = pluriel) ou avec des conventions différentes <sup>2</sup> (Ioannidou et Kyriacopoulou, 2010). Nous avons choisi de garder au maximum les notations utilisées dans les tables du Lexique-Grammaire du français. La table des classes contenait au départ 280 propriétés, incluant les différentes notations. À partir de la table des classes, nous avons repéré les erreurs de notation et nous les avons corrigées directement dans les tables. La nouvelle table des classes générée contient 202 propriétés.

Cette étape, achevée pour les verbes, est en cours pour les noms prédicatifs. Le script de conversion des verbes est également en cours de réalisation, ce qui nous permettra de générer une première version du lexique *LGLex* des verbes grecs (Ioannidou et Tolone, 2011).

L'objectif est d'homogénéiser, corriger et compléter les données pour l'ensemble des tables du Lexique-Grammaire du grec. Une fois ces tables syntaxiques corrigées, elles seront converties au format LGLex, afin d'être exploitables dans des analyseurs syntaxiques.

6G: NO V N1, avec une complétive en N1

9G : N0 V N1  $\sigma\epsilon$  [ $se=\grave{a}$ ] N2, avec une complétive en N1

38GL: N0 V N1 Loc N2 source Loc N3 destination

38GLS : N0 V N1 Loc N2 source 38GLD : N0 V N1 Loc N2 destination

38GLH: N0 V N1 Loc N2 destination, avec N1 =: Nhum

 $38 \mathrm{GLR}: N0 \ V \ N1 \ Loc \ N2$  FN1:  $N0 \ \kappa \acute{\alpha} \nu \omega \ [k\acute{a}no=faire] \ N$ 

FN2 : N0  $\kappa \acute{\alpha} \nu \omega$  [káno=faire] N P $\nu \alpha$  [Pna=P avec conjonction na, suivie de phrases au subjonctif]

FNPN : N0  $\kappa \acute{\alpha} \nu \omega$  [káno=faire] N  $\mu \epsilon$  [me=avec] N1

FNAN-hum : N0  $\kappa \acute{\alpha} \nu \omega$  [káno=faire] N  $\sigma \epsilon$  [se=à] N1, avec N1 = : N-hum FNANhum : N0  $\kappa \acute{\alpha} \nu \omega$  [káno=faire] N  $\sigma \epsilon$  [se=à] N1, avec N1 = : Nhum FNANlieu : N0  $\kappa \acute{\alpha} \nu \omega$  [káno=faire] N  $\sigma \epsilon$  [se=à] N1, avec N1 locatif

FNDNAN : NO  $\kappa \acute{\alpha} \nu \omega$  [káno=faire] N N1genitif [équivalent à de N1]  $\sigma \epsilon$  [se=à] N2

Nous n'indiquons pas les structures de base des adverbes (semi-)figés, puisque ce sont les mêmes que pour le français.

2. Nous avons trois manières d'exprimer ce qui est optionnel en utilisant des parenthèses. D'une part, on peut mettre uniquement la partie optionnelle entre parenthèses et dans ce cas les parenthèses sont interprétés comme permettant d'inclure l'optionnel (N0 V N1 (Loc N2 source) Loc N3 destination). D'autre part, on peut mettre entre parenthèses la structure optionnelle suivie du symbole +, suivie ou précédé du symbole vide E, représentant la chaîne vide (N0 V N1 (Loc N2 source+E) Loc N3 destination et N0 V N1 (E+Loc N2 source) Loc N3 destination). Dans ce deuxième cas, les parenthèses sont interprétées comme incluant plusieurs sous-structures au choix, le choix étant exprimé par le symbole +. C'est la troisième notation qui a été choisie (c'est-à-dire le symbole + précédé du symbole E), afin de rester conforme aux notations du français.

# 11.2.2 Améliorer le lexique LGLex-Lefff du français et son intégration dans FRMG

Comme nous l'avons mentionné tout au long de cette thèse, le travail entrepris pour le français doit être poursuivi :

- des entrées sont à ajouter ou à coder dans les tables existantes (cf. 5.5.2); citons par exemple le codage des paraphrases des adverbes en -ment (notamment, le codage des propriétés lexicales associées) présentées en 6.5.1, ainsi que l'intégration des variantes des entrées adverbiales dans le lexique LGLex, comme montré dans la section 7.3 (Tolone et Voyatzi, 2011);
- de nouvelles tables sont à créer, ou simplement à numériser et corriger pour certaines encore restantes (cf. 5.2.4 et 5.5.2), comme les tables de L. Pivaut (Tolone, 2011);
- des propriétés sont à coder, aussi bien dans la table des classes que dans les tables elles-mêmes (cf. 5.5.2); de plus, certaines propriétés sont à ajouter, comme par exemple certaines constructions, notamment pronominales ou ayant la formation en général régulière (comme la négation ou les propositions relatives);
- les processus de conversion sont à améliorer, pour corriger les erreurs et tenir compte de plus d'informations;
- une évaluation plus fine est à réaliser afin de détecter précisément d'où viennent les erreurs d'analyse, permettant ainsi d'améliorer les tables et/ou l'analyseur FRMG (Tolone et al., 2011).

Tout d'abord, le travail de conversion nous a permis d'identifier un certain nombre de problèmes dans les données de départ (tables et table des classes), mais il nous a également conduit à un certain nombre de simplifications et d'approximations dans le processus de conversion.

Il subsiste en effet d'importantes possibilités d'améliorations :

- identifier et corriger les erreurs qui restent certainement encore à chacune des étapes du processus;
- tenir compte de certaines constructions qui sont ignorées;
- mieux gérer les cas difficiles comme les entrées ayant une construction de base avec une ou deux constructions définitoires, telles que les tables de symétriques ou de converses;
- récupérer la classe de fréquence dans le DELA, afin de la traduire en un poids de la façon suivante : les entrées z1 reçoivent un poids standard de 100, les entrées z2 reçoivent un poids de 70, et les entrées z3 reçoivent un poids de 50.
- intégrer les déterminants (et la présence de modifieurs) qui sont codées dans les tables de noms prédicatifs, qui sont jusqu'à présent ignorés;
- ajouter les informations sur la réduction du groupe nominal des noms prédicatifs, afin de clarifier l'attachement dans les groupes nominaux;
- finir la conversion des tables d'expressions figées qui a été amorcée (cf. 8.1.6), ce qui demande une modification complète des entrées dans les tables afin de déterminer leurs différents constituants et leur catégorie;
- convertir également les tables d'adverbes, en considérant toutes les variantes

comme des entrées supplémentaires (cf. section 7.3).

Cette thèse a permis de construire un lexique syntaxique pour le TAL à partir des tables du Lexique-Grammaire, avec en perspective l'amélioration de la qualité des outils et des ressources existants.

En effet, l'intégration dans l'analyseur framg doit être poursuivie :

- coupler les deux variantes de l'analyseur (FRMG<sub>LGLex</sub> et FRMG<sub>Lefff</sub>) pour garder un maximum d'analyses complètes, bien meilleures que les analyses partielles (cf. section 10.2);
- détecter des erreurs, notamment au moyen de techniques automatiques, telles que la fouille d'erreurs dans les sorties d'analyseurs syntaxiques (Sagot et de La Clergerie, 2008), en poursuivant le travail présenté dans la section 10.3 (Tolone et al., 2011);
- prendre en compte les noms prédicatifs avec déterminants, ce qui permettra une meilleure évaluation du lexique LGLex-Lefff puisque les noms prédicatifs sans déterminant, les moins nombreux dans les corpus, sont les seuls qui ont pu être évalués (cf. section 10.4). Du point de vue de l'analyse, autoriser des déterminants sur les noms prédicatifs fait exploser le nombre d'analyses; il est possible qu'une bonne approche soit une réécriture en sortie d'analyse syntaxique (dans la phase de désambiguïsation par exemple);
- prendre en compte des informations sémantiques (macros du type @fNhum ou @fNhum, où f est la fonction syntaxique) jusqu'à présent ignorées, ou d'autres informations, comme par exemple la macro @neg, qui indique le caractère obligatoirement négatif du verbe (cf. 8.1.4); une possibilité est de factoriser les entrées et de choisir une entrée particulière très tardivement;
- ajouter des constructions non gérées;
- prendre en compte les informations syntaxiques des adverbes, ignorées jusqu'à présent; les adverbes peuvent en effet être insérés à n'importe quel endroit de la phrase, sans aucune contrainte.

Enfin, ce travail doit aussi renforcer la fusion de diverses ressources lexicales en une seule ressource de très grande qualité, même si nous devons garder à l'esprit que les choix linguistiques derrière chaque ressource ont un impact : ainsi, le Lefff fournit des entrées verbales plutôt factorisées (peu de distinctions sémantiques, cadres de sous-catégorisation factorisés) alors que LGLex liste de nombreuses entrées par verbes correspondant à divers sens et associées à des cadres de sous-catégorisation plus simples mais se chevauchant.

Nous pouvons envisager d'améliorer LGLex-Lefff en le fusionnant avec, par exemple, le Lefff et/ou DICOVALENCE, en employant une méthode similaire à celle de Danlos et Sagot (2008) :

- conversion des ressources de départ au format Lefff;
- regroupement des entrées des différentes ressources;
- fusion des regroupements d'entrées.

Pour un lemme donné, chaque ressource est susceptible de comporter plusieurs entrées. Il faut donc déterminer le nombre d'entrées que l'on souhaite obtenir au final, afin de construire ces ensembles d'entrées provenant des différentes ressources, appelés regroupements.

Les entrées qui forment un regroupement doivent ensuite être fusionnées :

- l'ensemble des fonctions syntaxiques est construit comme l'union des ensembles des fonctions syntaxiques présentes dans les entrées sources;
- pour chaque fonction, l'ensemble des réalisations est également obtenu par union, en indiquant quelle source propose quelle réalisation;
- une fonction syntaxique n'est à réalisation obligatoire que si c'est le cas dans toutes les ressources sources;
- l'ensemble des redistributions possibles est construit comme l'union des ensembles de redistributions possibles présentes dans les entrées sources.

Ceci doit s'accompagner d'une validation manuelle, notamment des entrées qui se sont multipliées par rapport au nombre initial d'entrées du lemme concerné dans les tables du Lexique-Grammaire (étant considérée comme la ressource ayant le plus d'entrées par lemme).

L'utilisation d'une ressource lexicale la plus riche possible reste un moyen efficace pour améliorer la qualité d'un analyseur syntaxique (Sagot et de La Clergerie, 2008). Ceci constitue une des motivations pour poursuivre la construction et l'amélioration des tables du Lexique-Grammaire du français et d'autres langues.

# Chapitre 11 Conclusion et perspectives

# **Bibliographie**

- ABEILLÉ, A. (2002). Une grammaire électronique du français. CNRS Editions, Paris, France. 23, 52
- ABEILLÉ, A. (2003). Treebanks: Building and Using Parsed Corpora, volume 20 de Text, Speech and Language Technology. Kluwer Academic Publishers, Dordrecht, Pays-Bas. 30
- Aït-Mokhtar, S., Chanod, J.-P. et Roux, C. (2002). Robustness beyond shallowness: incremental deep parsing. *Natural Language Engineering*, 8(3):121–144. 22, 26
- ALCOUFFE, P., REVELLIN-FALCOZ, B. et ZAYSSER, L. (1993). Azote : des tables du LADL au format Genelex. *In Actes du colloque Informatiques et Langues Naturelles (ILN'93)*, IRIN, Université de Nantes, France. 70
- Alonso, M. et Díaz, V. (2003). Variants of mixed parsing of TAG and TIG. Traitement Automatique des Langues (T.A.L.), 44(3):41–165. 56
- Alonso, M. A., Cabrero, D., Vilares, M. et de La Clergerie, E. (1999). Tabular algorithms for TAG parsing. In Proceedings of the 9th Conference of the European Chapter of the Association for Computational Linguistics (EACL'99), pages 150–157.
- Baker, C., Fillmore, C. et Lowe, J. (1998). The Berkeley FrameNet project. *In Proceedings of ACL-CoLing'98*, Montreal, Canada. 14, 31, 70
- BÉCHET, N. (2009). Extraction et regroupement de descripteurs morpho-syntaxiques pour des processus de Fouille de Textes. Thèse de doctorat, Université Montpellier 2, Montpellier, France. 22, 25
- Blache, P. et Rauzy, S. (2006). Mécanismes de contrôle pour l'analyse en grammaires de propriétés. In Actes de la Conférence sur le Traitement Automatique des Langues Naturelles (TALN'06), pages 415–424, Louvain, Belgique. 25
- Blanc, O. (2006). Algorithmes d'analyse syntaxique par grammaires lexicalisées : optimisation et traitement de l'ambigüité. Thèse de doctorat, IGM, Université Paris-Est Marne-la-Vallée, France. 156

- Blanche-Benveniste, C., Delofeu, J., Stefanini, J. et van den Eynde, K. (1987). Pronom et syntaxe: L'approche pronominale et son application au français. SELAF, Paris, France. 27
- BOONS, J.-P., GUILLET, A. et LECLÈRE, C. (1976a). La structure des phrases simples en français : Classes de constructions transitives. Rapport technique, LADL, CNRS, Paris 7. 39, 67, 82, 100, 101, 102, 103, 104, 105, 107, 110
- BOONS, J.-P., GUILLET, A. et LECLÈRE, C. (1976b). La structure des phrases simples en français : Constructions intransitives. Droz, Genève, Suisse. 39, 67, 76, 77, 92, 100, 101, 104, 108, 110, 135, 200, 277, 293, 294, 299, 300
- BORILLO, A. (1971). Remarques sur les verbes symétriques français. *Langue française*, 11(1):17–31. 67, 109
- BOULLIER, P. et SAGOT, B. (2005). Analyse syntaxique profonde à grande échelle : SxLFG. Traitement Automatique des Langues (T.A.L.), 46(2):65–89. 22, 23
- BOURIGAULT, D. et Frérot, C. (2005). Acquisition et évaluation sur corpus de propriétés de sous-catégorisation syntaxique. In Actes de la Conférence sur le Traitement Automatique des Langues Naturelles (TALN'05), Dourdan, France. 26
- BRISCOE, T. et CARROLL, J. (1993). Generalized probabilistic LR parsing of natural language (corpora) with unification-based grammars. *Computational Linguistics*, 19(1):25–59. 26
- CABRERA, I. (2008). Alpage Linguistic Processing Chain for French. http://alpage.inria.fr/docs/alpchain-doc.pdf. 45, 52
- Candito, M.-H. (1999). Organisation modulaire et paramétrable de grammaires électroniques lexicalisées. Thèse de doctorat, Université Paris 7, France. 53
- Carroll, J. et Fang, A. C. (2004). The automatic acquisition of verb subcategorisations and their impact on the performance of an HPSG parser. *In* Su, K.-Y., ichi Tsujii, J., Lee, J.-H. et Kwong, O. Y., éditeurs: *IJCNLP*, volume 3248, pages 646–654. Springer. 26
- CERVELLE, J., FORAX, R. et ROUSSEL, G. (2006). Tatoo: an innovative parser generator. In Proceedings of the conference on Principles and Practices of Programming in Java (PPPJ'06), Mannheim, Allemagne. 158
- Chomsky, N. (1965). Aspects of the Theory of Syntax. MIT Press, Cambridge, Etats-Unis. 38
- CLÉMENT, L. (2001). XLFG: a parser to learn the LFG framework. In Proceedings of the North American Chapter of the Association for Computational Linguistics (NAA-CL'01), Pittsburgh, États-Unis. 24

- CLÉMENT, L., SAGOT, B. et BERNARD, L. (2004). Morphology based automatic acquisition of large-coverage lexica. *In Proceedings of the 4th Language Resource and Evaluation Conference (LREC'04)*, pages 1841–1844, Lisbonne, Portugal. 46
- Collins, M. (2003). Head-driven statistical models for Natural Language Parsing. Computational Linguistics, 29(4):589–637. 20
- Constant, M. et Tolone, E. (2010). A generic tool to generate a lexicon for NLP from Lexicon-Grammar tables. In Gioia, M. D., éditeur: Actes du 27e Colloque international sur le lexique et la grammaire (L'Aquila, 10-13 septembre 2008), Seconde partie, volume 1 de Lingue d'Europa e del Mediterraneo, Grammatica comparata, pages 79–193. Aracne, Rome, Italie. ISBN 978-88-548-3166-7. 83, 94, 155, 156, 161, 243
- Crabbé, B. (2005). Représentation informatique de grammaires d'arbres fortement lexicalisées : le cas de la grammaire d'arbres adjoints. Thèse de doctorat, Université Nancy 2, France. 24
- Crabbé, B. et Candito, M. (2008). Expériences d'analyse syntaxique statistique du français. In Actes de la Conférence sur le Traitement Automatique des Langues Naturelles (TALN'08), pages 45–54, Avignon, France. 20
- Danlos, L. (1980). Représentation d'informations linguistiques : les constructions N être Prép X. Thèse de doctorat, Université Paris 7, France. 67, 131, 136, 137
- Danlos, L. (1985). La génération automatique de textes en langue naturelle. Masson, Paris, France. 26
- Danlos, L. (1988). Les phrases à verbe support  $\hat{e}tre$  prep. Langages, 23(90):23–37. 123, 137, 138
- Danlos, L. et Sagot, B. (2008). Constructions pronominales dans Dicovalence et le Lexique-Grammaire: Intégration dans le Lefff. In Constant, M., Gioia, M. D., Nakamura, T. et Vecchiato, S., éditeurs: Actes du 27ème Colloque Lexique et Grammaire (LGC'08), L'Aquila, Italie. 47, 156, 181, 226
- DE CHALENDAR, G. et NOUVEL, D. (2009). Modular resource development and diagnostic evaluation framework for fast NLP system improvement. In Proceedings of the Workshop SETQANLP on North American Chapter of the Association for Computational Linguistics Human Language Technologies (NAACL-HLT'09), Boulder, États-Unis. 22, 24
- de La Clergerie, E. (2002). Construire des analyseurs avec DyALog. In Actes de la Conférence sur le Traitement Automatique des Langues Naturelles (TALN'02), Nancy, France. 23, 56
- DE LA CLERGERIE, E. (2005a). DyALog: a tabular logic programming based environment for NLP. In Proceedings of 2nd International Workshop on Constraint Solving and Language Processing (CSLP'05), Barcelone, Espagne. 23, 52, 56, 58

- DE LA CLERGERIE, E. (2005b). From metagrammars to factorized TAG/TIG parsers. In Proceedings of IWPT'05 (poster), pages 190–191, Vancouver, Canada. 22, 23, 52, 54
- DE LA CLERGERIE, E., SAGOT, B., NICOLAS, L. et GUÉNOT, M.-L. (2009). FRMG: évolutions d'un analyseur syntaxique TAG du français. Communication à la journée ATALA: Quels analyseurs syntaxiques pour le français? (http://www.atala.org/Quels-analyseurs-syntaxiques-pour). 56, 57, 60, 61
- DE NÉGRONI-PEYRE, D. (1978). Nominalisations par être en et réflexivation (admiration, opposition, révolte et rage). Lingvisticæ Investigationes, 2(1):127–164. 67, 125
- DENDIEN, J. et PIERREL, J.-M. (2003). Le trésor de la langue française informatisé : un exemple d'informatisation d'un dictionnaire de langue de référence. Traitement Automatique des Langues (T.A.L.), 44(2):11–37. 29, 155
- Dubois, J. et Dubois-Charlier, F. (1997). Les verbes français. Larousse, Paris, France. 28, 29, 46
- Duchier, D., Le Roux, J. et Parmentier, Y. (2005). XMG: Un compilateur de métagrammaires extensible. In Actes de la Conférence sur le Traitement Automatique des Langues Naturelles (TALN'05), Dourdan, France. 24
- FERNÁNDEZ GONZÁLEZ, D. (2010). Cadena de procesamiento lingüístico para el español. Mémoire de D.E.A., Université de Vigo, Espagne. 46, 52, 223
- Francopoulo, G. (2008). Tagparser: well on the way to iso-tc37 conformance. In Proceedings of the 1st First International Conference on Global Interoperability for Language Resources (ICGL'08), Hong-Kong, Chine. 22, 24
- Francopoulo, G., Monte, G., Calzolari, N., Monachini, M., Bel, N., Pet, M. et Soria, C. (2006). Lexical Markup Framework (LMF). *In Proceedings of the 5th Conference on Language Resources and Evaluation (LREC'06)*, Gênes, Italie. 70, 156
- Gardent, C., Guillaume, B., Perrier, G. et Falk, I. (2005). Extracting subcategorisation information from Maurice Gross' grammar lexicon. *Archives of Control Sciences*, 15(3):253–264. In Memoriam Maurice Gross. Special issue on Human Language Technologies as a challenge for Computer Science and Linguistics. Part I. (2nd Language and Technology Conference). 69, 78, 156
- Gardent, C., Guillaume, B., Perrier, G. et Falk, I. (2006). Extraction d'information de sous-catégorisation à partir des tables du LADL. In Actes de la Conférence sur le Traitement Automatique des Langues Naturelles (TALN'06), Louvain, Belgique. 69, 86, 90, 156, 157, 172
- GIRY-SCHNEIDER, J. (1978). Les nominalisations en français : L'opérateur faire dans le lexique. Droz, Genève, Suisse. 67, 118, 119, 122

- GIRY-SCHNEIDER, J. (1987). Les prédicats nominaux en français : Les phrases simples à verbe support. Droz, Genève, Suisse. 67, 120, 121, 122, 131, 135
- GIRY-SCHNEIDER, J. (2005a). Les adjectifs intensifs : syntaxe et sémantique. Cahiers de Lexicologie, 86(1):163–178. 67
- GIRY-SCHNEIDER, J. (2005b). Les noms épistémiques et leurs verbes supports. Lingvisticæ Investigationes, 27(2):219–238. 67, 114
- GIRY-SCHNEIDER, J. et Balibar-Mrabti, A. (1993). Classes de noms construits avec avoir. Rapport technique, LADL, Université Paris 7. 67, 82, 113
- GRISHMAN, R., MACLEOD, C. et MEYERS, A. (1994). ComLex Syntax: Building a computational lexicon. In Proceedings of the 15th International Conference on Computational Linguistics (CoLing'94), pages 268–272, Kyoto, Japon. 13, 30, 70
- GROSS, G. (1989). Les constructions converses du français. Droz, Genève, Suisse. 67, 121, 123, 127
- GROSS, M. (1969). Remarques sur la notion d'objet direct en français. *Langue française*, 1(1):63–73. 87
- GROSS, M. (1975). Méthodes en syntaxe: Régimes des constructions complétives. Hermann, Paris, France. 5, 7, 14, 26, 27, 38, 39, 46, 67, 96, 97, 98, 99, 100, 123, 164, 281, 288
- GROSS, M. (1982). Une classification des phrases «figées» du français. Revue Québécoise de Linguistique, 11(2):151–185. 67, 100, 131
- GROSS, M. (1986a). Grammaire transformationnelle du français : Syntaxe de l'adverbe, volume 3. ASSTRIL, Paris, France. 67, 138
- GROSS, M. (1986b). Grammaire transformationnelle du français : Syntaxe du verbe, volume 1. Cantilène, Paris, France. 33, 35
- GROSS, M. (1988). Adjectifs composés. *Grammaire et histoire de la grammaire*, pages 211–233. Hommage à la mémoire de Jean Stefanini. 67, 131
- GROSS, M. (1990). La caractérisation des adverbes dans un Lexique-Grammaire. Langue française, 86(1):90–102. 138, 139, 223
- GROSS, M. (1996). Les formes être prép x du français. *Lingvisticæ Investigationes*, (2). 67, 131
- Guillet, A. et Leclère, C. (1992). La structure des phrases simples en français : Les constructions transitives locatives. Droz, Genève, Suisse. 39, 67, 77, 83, 100, 101, 102, 104, 106, 109, 110, 277, 293, 294, 299, 300

- Hamon, O., Mostefa, D., Ayache, C., Paroubek, P., Vilnat, A. et de La Cler-Gerie, E. (2008). Passage: from French parser evaluation to large sized treebank. In Proceedings of the 6th Language Resource and Evaluation Conference (LREC'08), Marrakech, Maroc. 5, 7, 20
- Harris, Z. (1952). Discourse analysis. Language, 28(1):1–30. 92
- HATHOUT, N. et NAMER, F. (1997). Génération (semi)-automatique de ressources lexicales réutilisables à grande échelle. *In Actes des 1ères JST FRANCIL, AUPELF-UREF*, Avignon, France. 80, 83, 91
- Hathout, N. et Namer, F. (1998). Automatic construction and validation of French large lexical resources: Reuse of verb theoretical linguistic descriptions. *In Proceedings of the 1st Language Resources and Evaluation Conference (LREC'98)*, Grenade, Espagne. 156, 157
- hye Han, C., Lavoie, B., Palmer, M., Rambow, O., Kittredge, R., Korelsky, T., Kim, N. et Kim, M. (2000). Handling structural divergences and recovering dropped arguments in a Korean/English machine translation system. In AMTA '00: Proceedings of the 4th Conference of the Association for Machine Translation in the Americas on Envisioning Machine Translation in the Information Future, volume 1934, pages 40–53, Londres, Angleterre. Springer Verlag. 26
- IDE, N. et VÉRONIS, J. (1994). MULTEXT: Multilingual text tools and corpora. In Proceedings of the 15th International Conference on Computational Linguistics (Co-Ling'94), pages 588–592, Kyoto, Japon. 24
- Ioannidou, K. et Kyriacopoulou, T. (2010). Lexique-Grammaire des verbes en grec moderne: Ambiguïtés formelles et analyse des textes. *In* Popović, L., Krstev, C., Vitas, D., Pavlović-Lažetić, G. et Obradović, I., éditeurs: *Actes du 29ème Colloque Lexique et Grammaire (LGC'10)*, Belgrade, Serbie. 223, 224
- IOANNIDOU, K. et TOLONE, E. (2011). Construction du lexique *LGLex* à partir des tables du Lexique-Grammaire des verbes du grec moderne. *In Actes du 30ème Colloque Lexique et Grammaire (LGC'11)*, Nicosie, Chypre. À paraître. 224
- Joshi, A. K. et Hopely, P. (1996). A parser from antiquity. *Natural Language Engineering*, 2(4):291–294. 19
- Joshi, A. K., Levy, L. et Takahashi, M. (1975). Tree Adjunct Grammars. *Journal of Computer and System Science* 10, 10(1):136–163. 23, 24, 52
- KIPPER, K., DANG, H. T. et PALMER, M. (2000). Class-based construction of a verb lexicon. In Proceedings of the 7th Conference on Artificial Intelligence (AAAI'00) and of the 12th Conference on Innovative Applications of Artificial Intelligence (IAAI'00), pages 691–696, Menlo Park, États-Unis. AAAI Press. 14, 30

- KIPPER-SCHULER, K. (2003). VerbNet: a broad coverage, comprehensive, verb lexicon. Thèse de doctorat, Université de Pennsylvanie, États-Unis. 30
- KLEIN, D. et MANNING, C. D. (2003). Accurate unlexicalized parsing. In Proceedings of Association for Computational Linguistics (ACL'03), pages 423–430, Sapporo, Japon. 20
- Kupść, A. (2007). Extraction automatique de cadres de sous-catégorisation verbale pour le français à partir d'un corpus arboré. *In Actes de la Conférence sur le Traitement Automatique des Langues Naturelles (TALN'07)*, Toulouse, France. 30
- KYRIACOPOULOU, T. (2010). Lexique-Grammaire des verbes en grec modernes : bilan et perspectives. Cahiers du CENTAL, 6:181–189. Mélanges en hommage à Christian Leclère. 223
- LABELLE, J. (1974). Étude de constructions avec opérateur avoir (nominalisations et extensions). Thèse de doctorat, LADL, Université Paris 7, France. 67, 128
- Laporte, E. (2005). Une classe d'adjectifs de localisation. Cahiers de Lexicologie, 86:145–161. 67
- LAPORTE, E. (2008). Exemples attestés et exemples construits dans la pratique du Lexique-Grammaire. In Jacques François, éditeur : Observations et manipulations en linguistique : entre concurrence et complémentarité, volume 16 de Mémoires de la Société de linguistique de Paris. Nouvelle série, pages 11–32, Paris, France. Peeters. 91
- LAPORTE, E. (2010). Le Lexique-Grammaire est-il exploitable pour le traitement des langues? *Cahiers du CENTAL*, 6:207–218. Mélanges en hommage à Christian Leclère. 68, 69, 75, 77, 82, 87, 91
- Laurence, D., Benoït, S. et Susanne, S.-A. (2006). French frozen verbal expressions: from Lexicon-Grammar tables to NLP applications. *In Actes du 25ème Colloque Lexique et Grammaire (LGC'06)*, Palerme, Italie. 47, 186
- Laurent, D., Nègre, S. et Séguéla, P. (2009). L'analyseur syntaxique cordial dans Passage. In Actes de TALN'09 (session poster), Senlis, France. 22, 25
- LECLÈRE, C. (1990). Organisation du Lexique-Grammaire des verbes français. *Langue française*, 87(1):112–122. 67, 109, 136
- LEVIN, B. (1993). English Verb Classes and Alternations: a preliminary investigation. University of Chicago Press, Chicago, États-Unis. 14, 30, 91
- Macleod, C., Meyers, A., Grishman, R., Barrett, L. et Reeves, R. (1997). Designing a dictionary of derived nominals. *In Proceedings of Recent Advances in Natural Language Processing (RANLP'97)*, Tzigov Chark, Bulgarie. 14, 30

- MARTIN, J. (2006). Mieux comprendre les méta-grammaires. Mémoire de D.E.A., Université Paris 6, France. 53
- Mel'čuk, I. A., Arbatchewsky-Jumarie, N., Elnitsky, L. et Lessard, A. (1984, 1988, 1992, 1999). Dictionnaire explicatif et combinatoire du français contemporain : Recherches lexico-sémantiques. Presses de l'Université de Montréal, Montréal, Canada. Volumes I, II, III, IV. 26, 29
- Mel'čuk, I. A. et Polguère, A. (2006). Dérivations sémantiques et collocations dans le DiCo/LAF. Langue française, 150(2):66–83. 29
- MESSIANT, C. (2010). Acquisition automatique de schémas de sous-catégorisation à partir de corpus bruts. Thèse de doctorat, Université Paris-Nord, France. 30
- MESSIANT, C., NAMAKURA, T. et VOYATZI, S. (2009). La complémentarité des approches manuelle et automatique en acquisition lexicale. *In Actes de TALN'09 (session poster)*, Senlis, France. (10 pp.). 30
- MEUNIER, A. (1981). Nominalisations d'adjectifs par verbes supports. Thèse de doctorat, LADL, Université Paris 7, France. 67, 82, 114, 115, 116, 123
- MOLINER, C. (1984). Étude syntaxique et sémantique des adverbes de manière en -ment. Thèse de doctorat, Université de Toulouse – Le Mirail, France. 138
- MOLINERO, M., SAGOT, B. et NICOLAS, L. (2009). A morphological and syntactic wide-coverage lexicon for Spanish: The Leffe. In RANLP 2009, Borovets, Bulgarie. 46
- MOLINIER, C. et Levrier, F. (2000). Grammaire des adverbes : description des formes en -ment. Droz, Genève, Suisse. 67, 138
- PAROUBEK, P., ROBBA, I., VILNAT, A. et AYACHE, C. (2006). Data annotations and measures in EASy: the evaluation campaign for parsers of French. *In Proceedings of the 5th Language Resource and Evaluation Conference (LREC'06)*, pages 315–320, Gênes, Italie. 20, 21
- PAROUBEK, P., ROBBA, I., VILNAT, A. et AYACHE, C. (2008). EASy, evaluation of parsers of French: what are the results? *In Proceedings of the 6th Language Resource and Evaluation Conference (LREC'08)*, Marrakech, Maroc. 20
- Paumier, S. (2001). Some remarks on the application of a Lexicon-Grammar. *Lingvisticæ Investigationes*, 24(2):245–256. 84
- PAUMIER, S. (2003). De la reconnaissance de formes linguistiques à l'analyse syntaxique. Thèse de doctorat, Université Paris-Est Marne-la-Vallée, France. 77, 83, 105, 156, 161, 200

- Picabia, L. (1978). Les constructions adjectivales en français : systématique transformationnelle. Droz, Genève, Suisse. 67
- PIVAUT, L. (1989). Verbes supports et vocabulaire technique : sport, musique et activités intelectuelles. Thèse de doctorat, LADL, Université Paris 7, France. 67, 129
- ROGERS, J. et VIJAY-SHANKER, K. (1992). Reasoning with descriptions of trees. *In Proceedings of Association for Computational Linguistics (ACL'92)*, pages 72–80, Louvain, Belgique. 54
- ROUSSANALY, A., CRABBÉ, B. et PERRIN, J. (2005). Premier bilan de la participation du loria à la campagne d'évaluation EASy. *In Actes de l'atelier EASy de TALN'05*, pages 49–52, Dourdan, France. 22, 24
- Ruwet, N. (1972). Théorie syntaxique et syntaxe du français. Seuil, Paris, France. 294
- SAGOT, B. (2005). Automatic acquisition of a Slovak lexicon from a raw corpus. In Text, Speech and Dialogue, 8th International Conference, TSD 2005, Karlovy Vary, Czech Republic, September 12-15, 2005, Proceedings, volume 3658 de Lecture Notes in Artificial Intelligence (LNAI), pages 156–163. Springer Verlag. ISBN 978-3-540-28789-6. 46
- SAGOT, B. (2006). Analyse automatique du français : lexiques, formalismes, analyseurs. Thèse de doctorat, Université Paris 7, France. 46
- SAGOT, B. (2010). The Lefff, a freely available and large-coverage morphological and syntactic lexicon for French. In Proceedings of the 7th Language Resources and Evaluation Conference (LREC'10), La Valette, Malte. 5, 7, 14, 27, 45, 47, 49, 257
- SAGOT, B. et BOULLIER, P. (2008). SXPipe 2 : architecture pour le traitement présyntaxique de corpus bruts. Traitement Automatique des Langues (T.A.L.), 49(2):155–188. 23
- SAGOT, B. et DANLOS, L. (2007). Améliorer un lexique syntaxique à l'aide des tables du Lexique-Grammaire: Constructions impersonnelles. *Cahiers du CENTAL*, 5:107–126. 14, 27, 45, 46, 49, 156
- SAGOT, B. et DE LA CLERGERIE, E. (2008). Fouille d'erreurs sur les sorties d'analyseurs syntaxiques. *Traitement Automatique des Langues (T.A.L.)*, 49(1):41–60. 46, 94, 207, 208, 209, 226, 227
- SAGOT, B. et FORT, K. (2007). Améliorer un lexique syntaxique à l'aide des tables du Lexique-Grammaire : adverbes en -ment. In Actes du 26ème Colloque Lexique et Grammaire (LGC'07), pages 145–152, Bonifacio, France. 47, 140
- SAGOT, B. et FORT, K. (2009). Description et analyse des verbes désadjectivaux et dénominaux en -ifier et -iser. Arena Romanistica, Journal of Romance Studies, 4:102–110. ISSN 1473-3536. 47

- SAGOT, B. et TOLONE, E. (2009a). Exploitation des tables du Lexique-Grammaire pour l'analyse syntaxique automatique. Arena Romanistica, Journal of Romance Studies, 4:302–312. ISSN 1473-3536. 94, 205
- SAGOT, B. et TOLONE, E. (2009b). Intégrer les tables du Lexique-Grammaire à un analyseur syntaxique robuste à grande échelle. *In Actes de TALN'09 (session poster)*, Senlis, France. (10 pp.). 94, 175, 205
- Salkoff, M. et Valli, A. (2005). A dictionary of French verbal complementation. In Proceedings of the 2nd Language and Technology Conference (LTC'05), Poznań, Pologne. 29
- SCHABES, Y. et WATERS, R. (1995). Tree Insertion Grammar: a cubic-time, parsable formalism that lexicalizes context-free grammar without changing the trees produced. Fuzzy Sets and Systems, 76(3):309–317. 56
- Sfetsiou, V. (2007). Noms prédicatifs : méthode d'analyse pour des applications eléctroniques. Thèse de doctorat, Université Aristote de Thessalonique, Grèce. 223
- Surdeanu, M., Harabagiu, S. M., Williams, J. et Aarseth, P. (2003). Using predicate-argument structures for information extraction. *In Proceedings of Association for Computational Linguistics (ACL'03)*, pages 8–15. 26
- THOMASSET, F. et DE LA CLERGERIE, E. (2005). Comment obtenir plus des métagrammaires. In Actes de la Conférence sur le Traitement Automatique des Langues Naturelles (TALN'05), Dourdan, France. 5, 7, 14, 22, 23, 53, 56, 57, 60, 175
- TOLONE, E. (2009). Les tables du Lexique-Grammaire au format TAL. *In Actes de MajecSTIC 2009*, Avignon, France. (8 pp.). 20, 65, 81, 88, 94, 97, 155, 195, 243
- TOLONE, E. (2010). Constructions définitoires des tables du Lexique-Grammaire : Le cas des complétives et des infinitives. *In Actes de MajecSTIC 2010 (session poster)*, Bordeaux, France. (4 pp.). 96
- Tolone, E. (2011). Conversión de las tablas del Léxico-Gramática del francés en el léxico *LGLex*. 2nd Argentinian Workshop on Natural Language Processing (WNLP'11). À paraître. 129, 225
- Tolone, E. et Sagot, B. (2011). Using Lexicon-Grammar tables for French verbs in a large-coverage parser. In Vetulani, Z., éditeur: Human Language Technology, Forth Language and Technology Conference, LTC 2009, Poznań, Poland, November 2009, Revised Selected Papers, Lecture Notes in Artificial Intelligence (LNAI). Springer Verlag. À paraître. 94, 175, 205, 257
- Tolone, E., Sagot, B. et de La Clergerie, E. (2011). Évaluation de lexiques syntaxiques par leur intégration dans l'analyseur syntaxique frmg. In Actes du 30ème Colloque Lexique et Grammaire (LGC'11), Nicosie, Chypre. À paraître. 209, 225, 226

- TOLONE, E. et VOYATZI, S. (2011). Extending the adverbial coverage of a NLP oriented resource for French. *In Proceedings of IJCNLP'11 (poster)*, Chiang Mai, Thaïlande. À paraître. 140, 166, 225
- Tolone, E., Voyatzi, S. et Leclère, C. (2010). Constructions définitoires des tables du Lexique-Grammaire. *In Popović*, L., Krstev, C., Vitas, D., Pavlović-Lažetić, G. et Obradović, I., éditeurs: *Actes du 29ème Colloque Lexique et Grammaire (LGC'10)*, pages 321–331, Belgrade, Serbie. 100, 108, 112, 131, 138, 139
- VAN DEN EYNDE, K. et MERTENS, P. (2003). La valence : l'approche pronominale et son application au lexique verbal. *Journal of French Language Studies*, 13:63–104. 27
- VAN DEN EYNDE, K. et MERTENS, P. (2006). Le dictionnaire de valence DICOVALENCE: manuel d'utilisation. http://bach.arts.kuleuven.be/dicovalence/manuel\_061117.pdf. 27, 28, 46, 49, 180
- Vanrullen, T., Blache, P. et Balfourier, J.-M. (2006). Constraint-based parsing as an efficient solution: Results from the parsing evaluation campaign EASy. *In Proceedings of the 5th Language Resource and Evaluation Conference (LREC'06)*, Gênes, Italie. 22, 25
- Vanrullen, T., Blache, P., Portes, C., Rauzy, S., Maeyhieux, J.-F., Guénot, M.-L., Balfourier, M.-L. et Bellengier, J.-M. (2005). Une plateforme pour l'acquisition, la maintenance et la validation de ressources lexicales. *In Actes de la Conférence sur le Traitement Automatique des Langues Naturelles (TALN'05)*, Dourdan, France. 29
- Veronis, J. (1998). Multext-lexicons, a set of electronic lexicons for european languages. CD-ROM distributed by ELRA/ELDA. 47
- VIJAY-SHANKER, K. (1987). A study of Tree Adjoining Grammar. Thèse de doctorat, Université de Pennsylvanie, États-Unis. 24, 52
- VIVÈS, R. (1983). Avoir, prendre, perdre : constructions à verbe support et extensions aspectuelles. Thèse de doctorat, LADL, Université Paris 7, France. 67, 74, 123, 126
- VOYATZI, S. (2006). Description morpho-syntaxique et sémantique des adverbes figés en vue d'un système d'analyse automatique des textes grecs. Thèse de doctorat, Université Paris-Est Marne-la-Vallée, France. 223
- VOYATZI, S. et KAKOYIANNI-DOA, F. (2010). The electronic dictionary of Modern Greek adverbs. In 30th Annual Meeting of the Department of Linguistics, Faculty of Philology, Aristotle University of Thessaloniki, Studies in Greek Linguistics, pages 149–161. 223

Bibliographie

# Cinquième partie Annexes



# Format du lexique LGLex

The *LGLex* lexicon is a syntactic lexicon of French verbs, predicative nouns, frozen expressions and adverbs generated by the *LGExtract* tool (Constant et Tolone, 2010) from the Lexicon-Grammar tables under LGPL-LR license. It is available both in text and XML format.

For more details about the modifications of tables, see (Tolone, 2009).

#### Remark:

Some tables of nouns have also morphologically derived verb:

f1a,f1b,f1c,f1d,f1r,f2a,f2b,f2c,f21,f3,f4,f5,f9,ad,dr1,drc,es,fr1,fs1,is1

Others have morphologically derived adjective:

an01,an02,an03,an04,an05,an06,ansy,es

In addition, the entries of the adverb table peco are also predicative adjectives, while those of the adverb tables ppco and pvco are also frozen expressions.

These additional entries, in addition to being mentioned in the complete lexicon, were extracted in the directory extra-lexicon/.

# A.1 Description of the content of the LGLex lexicon

In XML format, you have the element **<syn-lexicon>**:

Each entry is delimited by the tag **<entry>** with an attribute id which is the entry identifier generated by concatenating its grammatical category, its class (or table) it comes from and the index of the entry in the table. For instance, in **<entry id="V\_33\_24" status="completed">**, the identifier is **V\_33\_24**, which correspond to the 24th entry in the verb class 33. The status can be **completed** for a fully coded entry, **to complete** for an entry that has at least one property uncoded, or **to encode** for an entry that has

at least half of its properties uncoded.

Note: We call here a property encoded, a property present in the table and coded  $\sim$ . This ignores the coding O in the table of classes also means that the property must be encoded, but not listed in the table.

Then, information is gathered in four different tags:

- < lexical-info>: lemma and lexical information;
- <arguments>: arguments and their nature;
- <all-construction>: accepted constructions;
- **<example>**: an illustrative example.

#### A.1.1 Lexical information

<lexical-info> contains lexical information corresponding to the entry and has an attribute cat indicating its category (verb, noun for predicative noun, adj for predicative adjective, expr for frozen expression and adverb):

#### For verbs ONLY:

- <lexical-value> includes <lemma>, the value of which is the lemma of the entry, that can be completed with preverbal pronouns like se, y, en, le, la, les and/or the negation ne ... pas when they are obligatory in this entry (tags <ppvse>, <ppvy>, <ppven>, <ppvle>, <ppvle>, <ppvle>, <neg> with the attribute value true);
- <aux> indicates the possible auxiliaries accepted by this entry. It contains a list including the tags <avoir> or <être> with value true;
- < traduction > contains for some entries the translation of the lemma in English;

For nouns, adjective, frozen expressions and adverbs:

- <lexical-value> is composed of element <complete>, the value of which is the
whole entry (it can be multiword) and the elements <noun1>, <adj1>, <det2>,
 <noun2> (for nouns), containing the values of its different components. The
morphologically derived adjective (resp. verb) might also be indicated in tag
 <adjassoc> (resp. <verbassoc>). Complete list of elements for all categories:
 <adj>, <adj1>, <adv>, <adv1>, <c>, <c0>, <c02>, <c1>, <c12>, <c2>,
 <c3>, <cc>, <cv>, <cv>, <conj>, <conj2>, <conjcoord>, <conjsub>, <det>,
 <det0>, <det02>, <det1>, <det12>, <det2>, <det3>, <detc>, <detv>,
 <ilya>, <modif>, <MPA>, <noun1>, <noun2>, <nv>, <prep>, <prep>,
 , <prep0>, <prep1>, <prep2>, <prep3>, <prepdetv>, <prepc>, <prepc>, <prepv>,
 <verb>, <verb2>, <comme>, <ce>, <il>, <ca> and also <adjassoc>,
 <advassoc>, <ppevenassoc>, <ppevenassoc>, <ppevenassoc>, <ppevenassoc>, <ppevenassoc>, <ppvepvenassoc>, <ppvepven

For nouns and frozen expressions:

- <Vsup> describes the support verbs associated with the deverbal noun(or the frozen expression made of an adjective or an adverb and a support verb). It contains

<cat>, which has always the value verb and a list of <value>, representing the possible lexical values of the support verb part of basic construction of the entry;
For nouns ONLY:

- <Vconv> is constructed in the same manner of <Vsup> and refers to a second list of lexical values for the converse support verb Vconv as it can appear in some converse constructions (e.g. N1 Vconv Det N à N0);
- <det-modif-list> includes a list of <determiner-modifier> which indicates the distribution of determiners with possible modifiers for the noun. <determiner-modifier> has a tag <det>, which indicates the possible determiners separated by + (the value <E> stands for the absence of determiner). Tag <modifier> indicates whether the noun accept a modifier with the defined determiners. This can be completed with <value-modif>, which indicates the possible modifiers separated by +;

#### For verbs and nouns:

- - - - prepositions> contains a sequence of cpreposition> with an attribute id, corresponding to the number of the argument it introduces in the elementary construction (0 for subject, 1 for the first argument, 2 for for the second one, ...). In
cpreposition>, cpresents the different lexical values of the preposition.
For instance, the deverbal noun allergie (allergy) in table an01 uses support verb
avoir (have) and enters the elementary sentence N0 Vsup Det N Prép N1. The preposition associated with argument 1 is specified as follows:

In the first complement (Prép N1), the preposition has the value à: e.g., Léa a une certaine allergie à la poussière (Lea is allergic to dust);

<locatifs> defines the locative preposition distributions. It contains a sequence of
 <locatif> with an attribute id, referring to the number of the associated argument.
 Element <loc> also has a list of <prep>, representing the possible lexical values of the locative prepositions.

# A.1.2 Distribution of arguments

<arguments> describes the distribution of the different arguments (subject and complements) of the entry. It includes a set of <constituent> having an attribute pos, that indicates the number of the associated argument in the elementary sentence that the entry enters. A constituent is a list of <component>, each of them having the following elements:

- <cat> which has an attribute specifying its syntactic nature: NP for noun phrase,

- inf for infinitive (V-inf W), comp for a complementizer phrase (Qu P), leFaitComp for the noun phrase le fait que P, siPOuSiP for the specific complementizer phrase si P ou si P and adj for an adjective;
- Various semantic features <hum> (human), <nothum> (non human), <plobl> (obligatory plural), <npr> (proper noun), <abst> (abstract) and <conc> (concrete) with the value true when they are verified;

#### For verbs ONLY:

Other semantic features are possible for verbs: <source>, <destination>,
 <beneficiaire> (beneficiary), <detrimentaire> (detrimental), <apparition> (appearance), <disparition> (disappearance), <mesure> (measure), <pri>(price); and for nouns: <coll> (collective noun), <plur> (plural);

There also exist several other optional features:

- <mood> with an attribute indicating the mood of the complementizer phrase (ind for indicative and subj for subjunctive);
- <contr> with an attribute indicating the number of the argument that controls
  the infinitive. In the previous example, the distribution of the argument at position
  1 (i.e., the first complement Prép N1) is described as follows:

```
<arguments>
   . . .
  <constituent pos="1">
    <component>
      <cat value="inf" />
      <contr value="0" />
    </component>
    <component>
      <cat value="ceComp" />
      <mood value="ind" />
    </component>
    <component>
      <cat value="ceComp" />
      <mood value="subj" />
    </component>
    <component>
      <cat value="NP" />
      <nothum value="true" />
    </component>
  </constituent>
</arguments>
```

The complement Prép N1 can be:

- an infinitive controlled by argument 0, i.e., the subject N0: e.g., Léa a une allergie

à travailler (Lea is allergic to work):

- a complementizer phrase in the indicative: e.g, *Léa a une allergie* à ce que nous voyageons (*Lea is allergic* to the fact that we travel);
- a complementizer phrase in the subjective: e.g., Léa a une allergie à ce qu'il fasse beau (Lea is allergic to shine);
- a noun phrase (see previous example).

#### For verbs ONLY:

- <origin> contains the list <orig>, which indicates the complete name of the columns in the table, that has been used to define the distribution;
- <introd-prep> contains a sequence of <prep>, providing the prepositions introducing the argument and indicating their lexical values;
- <introd-loc> contains a sequence of <loc>, providing the locative prepositions that introduce the argument and indicating their lexical values.

#### A.1.3 Constructions

<all-constructions> list the different constructions that are accepted by the entry:

- <absolute-constructions> includes a list of absolute <construction>, which values are the titles of the columns entirely specifying the accepted construction with all its constituents. For instance, in the construction N0 V N1 Prép N2, N0 represents the subject, V indicates the verbal entry, N1 is the first complement and Prép N2 is the second one introduced by the preposition Prép. The construction title is preceded by the string o:: if the column associated with the construction has been coded + in the table (o) or true:: if it is a constant + in the table of classes (true). In this last case, the property is verified by all the entries of the table. Such properties are the definitional properties of each classes, including the base construction;
- <relative-constructions> contains the sequence of all relative <construction>,
   which values are the column titles of all columns specifying the name of the transformations that are applied on the base construction (e.g., [passif par]);

#### For nouns ONLY:

- <reductionsGN> describing reductions of the base sentence construction into another construction of another syntactic category, in the present case, noun phrase. Reductions are described with a list of <construction>, the value of which are the titles of the columns specifying the reduction construction (e.g., le N entre N0 et N1);
- <verbales> includes a list of verbal <construction>, which values are the titles of the columns specifying the construction which are accepted by the corresponding verbal entry (<verbassoc>);

#### For adverbs ONLY:

- <structureAdv> contains the base structure of the multiword adverb (e.g., Prép Det Adj C) and also its variants into a list of <construction> (e.g., Prép Det C).
 This structure represents Adv in the absolute and relative constructions (e.g., the ab-

solute construction  $N0\ V\ Adv\ W$  can be writted  $N0\ V\ Pr\acute{e}p\ Det\ Adj\ C\ W).$  For simple adverbs, the structure is not indicated because it's represented directly by Adv in the constructions.

### A.1.4 Example

<example> illustrates the entry (solely for verbs and nouns):

The value of **<example>** is an example of sentence with the entry.

For verbs, all entries contains an example, whereas, for nouns, only a selection of nouns contains an example.

#### A.1.5 The LGLex lexicon in text format

An entry described in text format includes the same information and is represented as follows:

# A.2 Examples

# A.2.1 A verbal example of LGLex lexicon in the XML format

The verb candidater (to apply) in the table 33:

```
<entry id="V_33_24" status="completed">
  <lexical-info cat="verb">
    <le>ical-value>
      <lemma value="candidater" />
    </le>ical-value>
      <aux>
        <avoir value="true" />
      </aux>
    <locatifs />
    prepositions />
  </le>ical-info>
  <arguments>
    <constituent pos="0">
      <component>
        <cat value="NP" />
        <hum value="true" />
```

```
<origin>
          <orig value="NO =: Nhum" />
        </origin>
        <introd-prep />
        <introd-loc />
      </component>
    </constituent>
    <constituent pos="1">
      <component>
        <cat value="NP" />
        <nothum value="true" />
        <origin>
          <orig value="N1 =: N-hum" />
        </origin>
        <introd-prep />
        <introd-loc />
      </component>
    </constituent>
  </arguments>
  <all-constructions>
    <absolute-constructions>
      <construction value="true::NO V à N1" />
    </absolute-constructions>
    <relative-constructions>
      <construction value="[extrap]" />
      <construction value="Ppv =: y" />
    </relative-constructions>
  </all-constructions>
  <example>
    <example value="Max a candidaté à un poste" />
  </example>
</entry>
```

# A.2.2 Same example in text format

### A.2.3 A nominal example of LGLex lexicon in XML format

The noun bise in the table fnan, with support verb faire: faire la bise (to kiss on the cheeks):

```
<entry id="N_fnan_18" status="completed">
  <lexical-info cat="noun">
    <le>ical-value>
      <complete value="bise" />
      <noun1 value="bise" />
    </lexical-value>
    <Vsup>
      <cat value="verb" />
      <value value="faire" />
    </Vsup>
    <det-modif-list>
      <determiner-modifier>
        <det value="un+une" />
        <modif value="false" />
      </determiner-modifier>
      <determiner-modifier>
        <det value="un+une" />
        <modif value="true" />
      </determiner-modifier>
      <determiner-modifier>
        <det value="la" />
        <modif value="false" />
      </determiner-modifier>
    </det-modif-list>
    prepositions />
  </lexical-info>
  <arguments>
    <constituent pos="0">
      <component>
        <hum value="true" />
        <cat value="NP" />
      </component>
    </constituent>
    <constituent pos="1">
      <component>
        <hum value="true" />
```

```
<cat value="NP" />
      </component>
    </constituent>
  </arguments>
  <all-constructions>
    <absolute-constructions>
      <construction value="true::NO Vsup Det N à N1" />
      <construction value="true::NO Vsup Det N" />
    </absolute-constructions>
    <relative-constructions />
    <reductions />
  </all-constructions>
  <example>
    <example value="" />
  </example>
</entry>
```

## A.2.4 Same example in text format

```
ID=N_fnan_18;status=completed
lexical-info=[cat="noun",
              Vsup=[cat="verb",list=(value="faire")],
              noun=[notperm=[complete="bise"],noun1="bise"]],
              detN=[list-det-modif=(det-modif=[det="un+une",modif="false"],
                                    det-modif=[det="un+une",modif="true"],
                                    det-modif=[det="la",modif="false"]),
              prepositions=()]
args=(const=[pos="0",
             dist=(comp=[hum="true",cat="NP"])],
      const=[pos="1",
             dist=(comp=[hum="true",cat="NP"])])
all-constructions=[absolute=(construction="true::NO Vsup Det N à N1",
                             construction="true::NO Vsup Det N"),
                   relative=(),
                   verbales=(),
                   reductionsGN=()]
example=[example=]
```

# $Annexe\ A\ Format\ du\ lexique\ LGLex$

# B

## **Génération du lexique** LGLex à l'aide de LGExtract

L'utilisation de l'outil *LGExtract* pour générer le lexique *LGL*ex est :

java fr.umlv.lgextract.LGExtract --script <script> --tableDirPath
<tableDirPath> --headerColumn <headerColumn> --headerRow <headerRow> [--debug]
[--tdtValues <tdtValues>] [--values <values>] [--output <output>] <tdt>

avec les paramètres suivants :

--script <script>

Chemin du script (le script doit être encodé en UTF-8)

--tableDirPath <tableDirPath>

Chemin du répertoire contenant les tables

--headerColumn <headerColumn>

Numéro de colonne où commencent les en-têtes de propriétés dans la table des classes (la première colonne est  $\mathbf{0}$ )

#### --headerRow <headerRow>

Numéro de ligne où commencent les en-têtes de tables dans la tables des classes (la première ligne est  $\mathbf{0}$ )

#### [--debug]

Indique que le programme est lancé en mode debug (si n'est pas présent, il est lancé en mode normal)

```
[--tdtValues <tdtValues>]
```

Chemin du fichier contenant les interprétations des valeurs dans la table des classes. Par défaut : interprétation de la valeur du Lexique-Grammaire standard

```
[--values <values>]
```

Chemin du fichier contenant les interprétations des valeurs dans les tables du Lexique-Grammaire. Par défaut : interprétation de la valeur du Lexique-Grammaire standard

```
[--output <output>]
```

```
Types de sorties : texte (txt) ou XML (xml). Valeur par défaut : txt
```

```
[--tableFormat <tableFormat>]
```

```
Format des tables : Excel (xls) ou CSV (csv). Valeur par défaut : csv
```

<tdt>

Liste des tables des classes utilisées

Les bibliotèques externes utilisées sont :

- Tatoo (http://tatoo.univ-mlv.fr/) : utilisé pour parcourir le script de configuration [tatoo-runtime.jar]
- Velocity-dep (http://mvnrepository.com/artifact/velocity/velocity-dep):
   utilisé par Tatoo [velocity-dep-1.4.jar]
- JDom (http://www.jdom.org/) : utilisé pour généré la sortie XML [jdom.jar]
- JExcelApi (http://jexcelapi.sourceforge.net/) : utilisé pour parcourir les fichiers Excel [jxl.jar]
- JSAP (http://martiansoftware.com/jsap/) : utilisé pour parcourir la ligne de commande des arguments [JSAP-2.1.jar]

Les fichiers d'archive .jar de ces bibliotèques sont inclus dans le répertoire jar. Ils doivent être ajoutés à la variable CLASSPATH pour utiliser LGExtract. Exemple :

```
export CLASSPATH=$CLASSPATH:classes:jar/tatoo-runtime.jar:jar/
    velocity-dep-1.4.jar:jar/jxl.jar:jar/JSAP-2.1.jar:jar/jdom.jar
```

Détaillons les différents fichiers utilisés avec l'outil LGExtract :

 8 exécutables prédéfinis permettent de lancer l'outil LGExtract sur une catégorie donnée (verbes, noms prédicatifs, expressions figées ou adverbes) et de créer le lexique LGLex au format texte ou XML.

Notons que l'utilisation de ces exécutables requiert la création de la variable d'environnement TABLESPATH dans *.bashrc*, indiquant le chemin du répertoire principal contenant toutes les données (tables) et l'outil LGExtract (en adaptant le path du répertoire tables/):

```
export TABLESPATH="$HOME/tables"
Voici quelques exemples :
./launch (affiche l'aide)
./launch_verbes > $TABLESPATH/lglex/verbes-lglex.txt
./launch_noms-predicatifs > $TABLESPATH/lglex/noms-predicatifs-lglex.txt
./launch_figees > $TABLESPATH/lglex/figees-lglex.txt
./launch_adverbes > $TABLESPATH/lglex/adverbes-lglex.txt
./launch_verbes_xml > $TABLESPATH/lglex/verbes-lglex.xml
./launch_noms-predicatifs_xml
 > $TABLESPATH/lglex/noms-predicatifs-lglex.xml
./launch_figees_xml > $TABLESPATH/lglex/figees-lglex.xml
./launch_adverbes_xml > $TABLESPATH/lglex/figees-lglex.xml
./launch_adverbes_xml > $TABLESPATH/lglex/adverbes-lglex.xml
./lau
```

- 4 scripts de configuration (avec l'extension .lg), un par catégorie (lgc\_verbes.lg, lgc\_noms-predicatif.lg, lgc\_figees.lg et lgc\_adverbes.lg). Les fichiers de configuration sont encodé en UTF-8;
- 2 fichiers (facultatifs) spécifiant la signification des différentes valeurs dans les tables et dans la table des classes.

Leur format est : symbole s suivi d'un espace, suivi de la signification **true** ou **false**. tables-values.txt contient :

- + true
- false
- ~ false

tablesOfClasses-values.txt contient:

- + true
- false
- / false
- ?+ false
- ?- false
- ? false
- 0 false

Des symboles tels que le chiffre 0 au lieu de la lettre O, ou tout autre erreur possible, peuvent être ajoutés;

 2 fichiers supplémentaires utilisés lors de la création des tables des classes et des scripts de configuration, mais non utiles pour la génération du lexique LGLex :
 1 exécutable makeTableOfClasses permettant de construire la table des classes au format Excel.

L'utilisation est:

java LGExtractTableOfClasses <dirpath of tables> <output xls file>  $\operatorname{Voici}$  un exemple :

./makeTableOfTables ../verbes tdt-verbes.xls

## Annexe B Génération du lexique LGLex à l'aide de LGExtract

1 script Perl list2code.pl permettant de générer automatiquement du code .lg à partir d'un fichier .txt contenant des constructions (une par ligne).



## Format du lexique LGLex-Lefff

The LGLex-Lefff lexicon is a syntactic lexicon of French verbs and predicative nouns converted in the Lefff format (Tolone et Sagot, 2011) from the LGLex lexicon. For more details about the Lefff lexicon and the framework it is based on, named Alexina, see Sagot (2010).

## **C.1** Description of the intensional Lefff format

Each entry in the intensional lexicon corresponds to a unique meaning of the corresponding lemma. It contains the following information:

- an entry identifier generated by concatenating its grammatical category, its class (or table) it comes from and the index of the entry in the table;
- a morphological class, which defines the patterns that build its inflected forms, using inflection classes from the Lefff;
- a category (or part-of-speech);
- the initial sub-categorization frame;
- additional syntactic information represented by macros;
- the list of possible redistributions;
- an example of sentence with the entry;
- a comment after the # sign.

For example, the intensional entry in the LGLex-Lefff lexicon for the French lemma  $clouer_{--}V_{-}36SL_{-}28$  (to nail) is as follows:

```
<Suj:cln|sn,Obj:sn,Loc:(avec-sn|et-sn|à-sn|sur-sn)>;
cat=v;
%actif,%passif,%ppp_employé_comme_adj
Ex.: Max a cloué cette planche(avec+contre+sur)celle-là
# BASE CONSTR = NO V N1 Loc N2 (NO V N1 et N2;
   NO V N1 Prép N2; NO V N1hum Loc N2abs; NO V N1)
   [[passif par]] <>; orig base constr = NO V N1 Loc N2
```

It describes a transitive entry with the following information:

- its identifier is V<sub>36</sub>SL<sub>28</sub>, which correspond to the 28th entry in the verb class 36SL;
- its morphological class is *v-er:std*, the class of standard first-conjugation verbs (ending -er);
- its semantic predicate can be represented by the Lemma as is, i.e., clouer;
- its category is verb (v);
- it has three arguments canonically realized by the syntactic functions Suj (subject),
   Obj (direct object) and Loc (locative argument); each syntactic function is associated with a list of possible realizations, but the Loc is optional as shown by the brackets;
- it allows for three different redistributions: %active, %passive, and %ppp\_employé\_comme\_adj;
- its example is Max a cloué cette planche(avec+contre+sur)celle-là (Max has nailed this board(with+by+on)that one).

## C.2 Description of the extensional Lefff format

The compilation process builds one extensional entry for each inflected form and each compatible redistribution, by inflecting the lemma according to the definition of its morphological class and by applying the formalized definitions of these redistributions. For example, the only inflected forms of *clouer* that are compatible with the passive redistribution are the past participle forms. The extensional passive entry for *cloués* (nailed) is the following (Kmp is the morphological tag for past participle masculine plural forms):

The original direct object (*Obj*) has been transformed into the passive Subject, and an optional Agent (*Obl2*) realized by a noun phrase preceded by a preposition (*par-sn*) was added.

## C.3 Characteristics of the LGLex-Lefff lexicon

### **C.3.1 Syntactic functions**

For verbs, the Lefff format uses the following syntactic functions:

- Suj for subject: cliticization with the nominative clitic;
- Obj for direct object: cliticization with the accusative clitic, commutable with ceci/cela (this/that), impacted by passivization when it is possible;
- Objà for indirect object canonically introduced by the preposition à: commutable with  $\grave{a}+non\text{-}clitic\ pronoun\ but\ not\ with\ ici\ (here)\ or\ l\grave{a}(-bas)\ (there),\ may\ be\ cliticizable\ into\ the\ dative\ clitic\ or\ y;$
- Objde for indirect object introduced by the preposition de: cliticization with en, not commutable with d'ici (from here) or de là (from there);
- Loc for locative argument: commutable with  $ici\ (here)$  or  $la(-bas)\ (there)$ , cliticizable with y: e.g., a Paris in Pierre va a Paris (Peter goes to Paris);
- Dloc for delocative argument: commutable with d'ici (from here) or de là (from there), cliticizable with en: e.g., de Paris in Pierre vient de Paris (Peter comes from Paris);
- Att for (subject, object or à-object) attribute and pseudo-object: e.g., 3 euros in J'ai acheté ceci 3 euros (I bought this 3 euros);
- Obl and Obl2 for other oblique arguments (non-cliticizable); Obl2 is used for verbs with two oblique arguments, such as plaider auprès de quelqu'un en faveur de quelqu'un d'autre (to plead in front of somebody for somebody else).

For predicative nouns, that can be headed by a support verb, the same set of functions are used.

#### C.3.2 Realizations

For verbs and nouns, possible realizations are threefold:

- clitic pronouns: cln for nominative clitic: e.g., il in Il donne ce livre à Marie (He gives this book to Mary), cla for accusative clitic: e.g., le in Il le donne à Marie (He gives it to Mary), cld for dative clitic: e.g., lui in Il lui donne ce livre (He gives her this book), y: e.g., Max y va (Max goes there), en: e.g., Max en mange (Max eats it);
- direct phrases: sn for noun phrase: e.g., La belle dame in La belle dame arrive (The beautiful lady arrives), sa for adjectival phrase: e.g., verte in La robe est verte (The dress is green), sinf for infinitive clause: e.g., dire aurevoir in Pierre est parti dire aurevoir (Peter left to say goodbye), scompl for completive clause: e.g., que Marie est belle in Pierre dit que Marie est belle (Peter says that Marie is beautiful), qcompl for interrogative clause: e.g., combien il gagne in Pierre dit combien il gagne (Peter said how much he earns);
- prepositional phrases: a direct phrase introduced by a preposition (e.g., à-sn, de-scompl, pour-sinf).

#### C.3.3 Redistributions

For verbs, the inventory of possible redistributions is the following:

- %actif, a dummy redistribution that has almost no effect on the initial subcategorization information;
- %passif for the standard passive in par: e.g., Jean assistait Max depuis des années
   → Max était assisté par Jean depuis des années (John has assisted Max for years
   → Max has been assisted by John for years);
- %passif\_de for the passive in de: e.g., Marie aime Pierre  $\rightarrow$  Pierre est aimé de Marie (Mary loves Peter  $\rightarrow$  Peter is loved by Mary);
- %actif\_impersonnel for active impersonal constructions with inverted subject, if any: e.g., Un accident est arrivé à Jean  $\rightarrow$  Il est arrivé un accident à Jean (An accident happened to John);
- %passif\_impersonnel for passive impersonal constructions with inverted subject, if any: e.g., Cette nouvelle information clarifie pourquoi Max est fâché → Il est clarifié par cette nouvelle information pourquoi Max est fâché (This new information clarifies why Max is angry → It is clarified by this new information why Max is angry);
- $\%ppp\_employ\'e\_comme\_adj$  for past participles used as adjectives: e.g.,  $Marie\ s'assoie$   $\rightarrow Marie\ est\ assise\ (Mary\ is\ sitting \rightarrow Mary\ is\ seated).$

Predicative nouns only use the *%default* redistribution that builds a final subcategorization frame which is identical to the initial one. In addition, they can have the *%passif* redistribution.

#### C.3.4 Macros

For verbs and nouns, macros represents additional syntactic information such as:

- control: for instance, @CtrlSujObj indicates that if it is realized as an infinitive clause, the object is controlled by the subject: e.g., chercher du pain is controlled by Pierre in Pierre va chercher du pain (Peter goes to get bread);
- mood of the complementizer phrase: @SCompInd indicates that if the subject is realized as a completive clause, its mood is indicative: e.g., qu'il fait beau in Pierre dit qu'il fait beau (Peter says that the weather is good); on the contrary, @CompSubj indicates that if the direct object is realized as a completive clause, its mood is subjunctive: e.g., qu'il fasse beau in Pierre veut qu'il fasse beau (Peter wants that the weather be good); the following abbreviations are used: S for subject, nothing for direct object, A for indirect object introduced by the preposition à, De for indirect object introduced by the preposition de; by default, the two modes are possible;
- human or non human noun phrase: @ObjàNhum indicates that the indirect object introduced by the preposition à can denote a person, or an animal linguistically assimilated to a person when is realized by a noun phrase: e.g., Vercingetorix s'est rendu à l'ennemi (Vercingetorix surrendered to the enemy); on the contrary,

@ObjàN-hum indicates that the indirect object introduced by the preposition  $\grave{a}$  can be non human: e.g., Jean s'est rendu  $\grave{a}$  mon opinion (John finally accepted my opinion); in this case, @ObjàNhum and @ObjàN-hum are not in the same entry because the sense of se rendre (to accept/to surrender) is different; in other cases, for instance, Max va tomber (Max goes down) and Le verre va tomber (The glass will fall), @SujNhum and @SujN-hum indicate that the subject can denote a human or a non human for the same entry; if no indication is given for an argument, we can consider both are always possible;

In addition, for verbs, there are other macros such as:

- auxiliary conjugation: @avoir: e.g., the verb achever in Max a achevé de peindre le mur (Max has finished painting the wall) or @être: e.g., the verb s'arrêter in Max s'est arrêté de boire (Max stopped drinking);
- pronominal verb: @pron: e.g., the verb arrêter in the previous example (s'arrêter);
- necessarily negative verb: @neg: e.g., the verb rajeunir in Que sa fille ait 20 ans ne rajeunit pas Max (His daughter being 20 years doesn't make Max feel very young);
- other clitic pronouns necessarily frozen with the verb: @pseudo-en: e.g., the verb baver in Max en bave avec Luc (Max has a hard time with Luc), @pseudo-y: e.g., the verb aller in Luc y va (Luc leaves), @pseudo-le: e.g., the verb disputer in La haine le dispute à la colère (Hate and ire are competing), @pseudo-la: e.g., the verb fermer in Fermez-la (Shut up), @pseudo-les: e.g., the verb aligner in Max les aligne à Luc (Max gives the money to Luc).



## **Génération du lexique** LGLex-Lefff à l'aide de LGLex2ilex

L'utilisation de LGLex2ilex pour générer le lexique LGLex est :

lglex2ilex.pl [options] {lefff\_files} < [lglex\_file] > [ilex\_file]

avec [lglex\_file] le fichier d'entrée, [ilex\_file] le fichier de sortie, {lefff\_files} une liste de fichiers .ilex du Lefff qui sont utilisés pour connaître la classe morphologique de chaque entrée.

Les [options] peuvent être :

-nuc ou - -no\_unknown\_construction

pour considérer que les constructions inconnues donnent lieu à la création d'entrées secondaires distinctes au lieu de créer des redistributions inconnues qui ne seront pas déductibles de la construction de base (cf. les deux types de traitement pour les constructions qui ne relèvent pas du cas 5 mais ne sont pas des variantes de la CBME dans 8.1.1).

-e [file] ou - -examples [file]

avec [file] un fichier contenant des exemples pour chaque entrée de chaque table, dont le format est :

<lemma><TAB><table\_id><TAB><first\_example>(<TAB><other\_examples>)

ce qui permet de récupérer les exemples de ce fichier plutôt que ceux des tables 1.

Voici un exemple d'utilisation (dans lefff/otherlex2lefff/)<sup>2</sup>:

<sup>1.</sup> Cette option peut être utilisée pour les verbes, puisqu'il existe un index électronique qui recense toutes les entrées en donnant plusieurs exemples (cf. 5.5.2).

<sup>2.</sup> La conversion des expressions figées étant en cours (cf. 8.1.6), le fichier *expr-lglex.ilex* n'est pas encore utilisable tel quel.

Les fichiers *v.ilex*, *v-phd.ilex* et *nom.ilex* font partie du Lefff mais ne servent ici qu'à attribuer la table de flexion. S'ils ne sont pas présents, les règles par défaut sont appliquées pour les mots dont la flexion n'est pas connue. À savoir, si c'est un mot en *-er*, on lui attribue la catégorie de verbe du premier groupe, etc. et par défaut c'est un mot invariable.

La description manuelle des lemmes qui se fléchissent de manière irrégulière (.mf) n'est pas utilisée par LGLex mais est nécessaire pour l'étape suivante. Les fichiers associées sont donc créés uniquement pour qu'ils existent (dans lefff/otherlex2lefff/) :

```
touch v-lglex.mf
touch npred-lglex.mf
```

Puis, on crée le lexique extensionnel (.lex) à partir du lexique intensionnel (.ilex) et de la description manuelle des lemmes qui se fléchissent de manière irrégulière (.mf) (dans lefff/):

```
make otherlex2lefff/v-lglex.lex
make otherlex2lefff/npred-lglex.lex
```

Les fichiers devant être dans le répertoire /exportbuild/src/lefff/ pour la suite, on crée des liens symboliques une fois pour toute :

```
ln -s otherlex2lefff/v-lglex.lex .
ln -s otherlex2lefff/npred-lglex.lex .
```

Ensuite, on crée le dictionnaire (.xlfg) pour FRMG (Lefff compilé) contenant toutes les entrées des divers fichiers du lexique extensionnel (.lex) provenant du Lefff et/ou des tables (dans lefff-frmg/):

make lglex



## Documentation des propriétés des tables de verbes distributionnels

Les Tab. E.1 à Tab. E.43 représentent la documentation complète des 551 propriétés syntaxico-sémantiques des tables de verbes. Pour chaque propriété nous indiquons sa nature (binaire ou lexicale), puis nous donnons sa définition en anglais <sup>1</sup> en l'illustrant d'un exemple.

<sup>1.</sup> La définition en français figure dans la documentation de la version 3.3 mais n'a pas été incluse ici.

| Feature                                 | Description of the feature   |
|---|--|
| (N1+N2) =: le fait Qu P                 | A locative object noted N1 or N2 can have an abstract meaning and take                 |
|   | the form le fait que P, close to a sentential complement                               |
| (binary)                                | Example: Max progresse vers le fait qu'il faut accepter la situation                   |
| (N1+N2) être V-n                        | A locative object noted N1 or N2 can become the subject of a sentence                  |
| (11)                                    | with $\hat{e}tre$ and a deverbal noun related with V as a 'predicate nominative'       |
| (binary)                                | Example: $Paul fouille dans le tiroir = Le tiroir est un fouillis$                     |
| (N1+N2) être V-n (forme                 | Form of a deverbal noun related with V, used when a locative object                    |
| V-n)                                    | noted N1 or N2 becomes the subject of a sentence with être and the                     |
| \ \ \                                   | deverbal noun as a 'predicate nominative'  |
| (lexical)                               | Example: fouillis  |
| (N2+N3) être V-n                        | A locative object noted N2 or N3 can become the subject of a sentence                  |
| (112   113) cere v ii                   | with être and a deverbal noun related with V as a 'predicate nominative'               |
| (binary)                                | Example: On emprisonne Max dans la cave = $La$ cave est une prison                     |
| (N2+N3) être V-n (forme                 | Form of a deverbal noun related with V, used when a locative object                    |
| V-n)                                    | noted N2 or N3 becomes the subject of a sentence with être and the                     |
| \ | deverbal noun as a 'predicate nominative'  |
| (lexical)                               | Example: prison  |
| (N2+N3) V N1                            | A locative object noted N2 or N3 can become the subject of a sentence                  |
| (142   143) V 141                       | with a direct object N1; the sentence is interpreted as a static result                |
| (binary)                                | Example: On emprisonne Max dans la cave = La cave emprisonne Max                       |
| (Nég, interro) => subj                  | Negation or interrogation in the main clause may change mood of sen-                   |
| (Neg, memo) => subj                     | tential complement to subjunctive  |
| (binary)                                | Example: Je crois qu'il viendra / Je ne crois pas qu'il vienne / Crois-                |
| (Siliary)                               | tu qu'il vienne?   |
| [extrap]                                | Subject extraposition, i.e. the subject can shift to a complement position             |
| [extrap]                                | while expletive $il$ is introduced in subject position                                 |
| (binary)                                | Example: Un malheur arrive à Paul / Il arrive un malheur à Paul                        |
| [passif de]                             | Passivization with agent introduced by the preposition $de$ ; all other                |
| [passir de]                             | objects are preserved  |
| (binary)                                | Example: Tout le monde a reconnu Marie à sa voix = Marie a été                         |
| (Siliary)                               | reconnue de tout le monde à sa voix  |
| [passif par]                            | Passivization with agent introduced by the preposition par; all other                  |
| [passii pai]                            | objects are preserved. In some cases, this feature is encoded as N1 être               |
|   | Vpp de N0 Prép N2. The direct object may be N2 where there is no N1                    |
| (binary)                                | Example: Paul a mangé la soupe dans un bol = La soupe a été mangée                     |
| (billary)                               | par Paul dans un bol   |
| <english></english>                     | Hint to a translation in English   |
| (lexical)                               | Example: Max vole chercher Ida: fly  |
| <ent>Ppv</ent>                          | Clitic forms frozen with the verb V. The information provided by this                  |
| \   Pv                                  | feature must agree with that provided by the binary features called Ppv                |
|   | =: en figé, etc.   |
| (lexical)                               | Example : Luc <b>n'en</b> revient pas de ce culot ; Luc <b>se</b> réserve pour la nuit |
| (10211001)                              | Example. Due it cit recover pur ue ee cuiot, Due se reserve pour in tiuti              |

TABLE E.1: Documentation des propriétés des tables de verbes (1)

| Feature                | Description of the feature  |
|------------------------|---|
| <ent>V</ent>           | Form of the verbal entry V. If an adverb is frozen with the verb, it is   |
|                        | part of the form. If clitics are frozen with the verb, they are not part of   |
|                        | the form. If a negative adverb is obligatorily present in the construction,   |
|                        | but has a free lexical value (pas, point, nullement, aucunement, aucun,   |
|                        | nul, personne, rien, guère, jamais, plus, nulle part), it is not part of the  |
|                        | form.   |
| (lexical)              | Example : Ce film dure longtemps : durer Advt ; Luc n'arrête pas d'être   |
|                        | dérangé : arrêter pas ; Votre geste ne va pas : aller   |
| <opt></opt>            | Sentence exemplifying the sense of the verbal entry V   |
| (lexical)              | Example : Max achève de peindre le mur; Max achève les blessés  |
| à N1 = Ppv =: le       | An object à N1 can be pronominalized into a clitic pronoun le   |
| (binary)               | Example: Paul apprend à lire = Paul l'apprend   |
| à N1 =: à ce Qu P = là | An object à N1 containing a sentential complement à ce que P can be   |
| ,                      | pronominalized into là  |
| (binary)               | Example: Toute cette histoire aboutit à ce que Luc a perdu = Toute cette  |
|                        | histoire aboutit là   |
| à N1hum = Ppv          | An object à N1 denoting a person can be pronominalized into a clitic  |
| a remain               | pronoun   |
| (binary)               | Example: Ceci correspond à Marie = Ceci lui correspond  |
| à N1-hum = Ppv         | An object à N1 with a non-human meaning can be pronominalized into  |
|                        | a clitic pronoun  |
| (binary)               | Example: Ceci correspond à un refus = Ceci y correspond   |
| a N2 = la              | An object à N2 can be pronominalized into $l\dot{a}$  |
| (binary)               | Example : Ceci l'a amené à se manifester = Ceci l'a amené là  |
| à Nhum =: Loc Npc      | A locative object Loc N2 can be replaced by à Nhum, denoting a person,  |
| a man = Loc mpc        | which is interpreted as Loc Nbp, where Nbp denotes the body or a body   |
|                        | part of the person  |
| (binary)               | Example: Luc assène un coup à Paul = Luc assène un coup sur le corps  |
| (billed y)             | de Paul. Luc arrache un cheveu à Paul = Luc arrache un cheveu de la   |
|                        | tête de Paul  |
| à Nhum destination     | A locative object noted Loc N2 or Loc N3, interpreted as a destination,   |
| d Wildin destination   | can take the form à Nhum, denoting a person   |
| (binary)               | Example: On a diffusé le match aux Bretons = On a diffusé le match  |
| (billed y)             | en Bretagne   |
| à Nhum source          | A locative object Loc N2, interpreted as a source, can take the form à  |
| a main source          | Nhum, denoting a person   |
| (binary)               | Example: Luc arrache un cheveu à Paul   |
| à quoi N0 V N1         | When the sentence follows another sentence in a discourse, an object à  |
| a quoi ivo v ivi       | N2 can take the form $\hat{a}$ quoi and the position in the beginning of the  |
|                        | sentence  |
| (hinamy)               |   |
| (binary) autre Loc1    | Example: () À quoi Paul a répliqué qu'il n'était pas d'accord  Prepositions of a locative object Loc N1 other than those represented in |
| autre Loci             | _ · · · · · · · · · · · · · · · · · · ·   |
| (lovicel)              | binary features  Example: Les convieres farandelent autour de la table: Les délinements   |
| (lexical)              | Example: Les convives farandolent autour de la table; Les délinquants   |
| autra Las?             | se recrutent (parmi+chez) les riches  |
| autre Loc2             | Prepositions of a locative object Loc N2 other than those represented in  |
| (1:-1)                 | binary features   |
| (lexical)              | Example : Max a découché de chez Léa; Max s'en vient chez vous  |

Table E.2: Documentation des propriétés des tables de verbes (2)

| Feature                    | Description of the feature   |
|----------------------------|--|
| Aux =: avoir               | V conjugates at compound tenses with auxiliary avoir                               |
| (binary)                   | Example : Que Max parte a très bien convenu à Luc                                  |
| Aux =: être                | V conjugates at compound tenses with auxiliary être                                |
| (binary)                   | Example: Max est entré livrer un colis   |
| de combien ?               | An additional complement introduced by the preposition $de$ , denoting             |
| de combien :               | a quantity or measurement related to the process, and usually with a               |
|                            | cardinal numeral, answers a question in de combien?                                |
| (binary)                   | Example: Luc approche la chaise de 50 cm; Luc approche la chaise de                |
| (Sincery)                  | combien?   |
| de N1 = de ce Qu P = de    | An object de N1 containing a sentential complement de ce que P can be              |
| là                         | pronominalized into $de l\grave{a}$  |
| (binary)                   | Example : La situation dérive de ce que tu as échoué = La situation                |
| (*,)                       | dérive de là   |
| de N1 V N0                 | The subject and an object de N1 can swap positions                                 |
| (binary)                   | Example : De ton silence dépend le succès de la mission                            |
| de N2 =: de combien ?      | An object de N2 can denote a quantity or measurement related to the                |
|                            | process, contain a cardinal numeral, and answer a question in de com-              |
|                            | bien?  |
| (binary)                   | Example : Paul a tapé Luc de 100 euros ; Paul a tapé Luc de combien ?              |
| de Nhum source             | The locative object de N2, interpreted as a source, can take the form de           |
|                            | Nhum, denoting a person  |
| (binary)                   | Example : On a éloigné l'assiette de Marie, On a soutiré de l'argent de            |
|                            | Luc  |
| dé-V                       | Sentence with verb-centered argument structure, with the same subject,             |
|                            | V with prefix $d\acute{e}$ , the same direct object N1, and sometimes the indirect |
|                            | object N2 with preposition de  |
| (binary)                   | Example : Luc décabosse la voiture. Le vent défleurit le jardin de tous            |
|                            | ces pavots   |
| en combien?                | An object en N2 answers a question in en combien?                                  |
| (binary)                   | Example : Luc a coupé le gâteau en combien? En quatre. *Luc a                      |
|                            | pulvérisé le verre en combien ? En 79 morceaux                                     |
| il être Vpp Prép N1 (E+par | Passive extraposition with N1, i.e. N0 V W = il être Vpp Prép N1 (E+par            |
| N0)                        | N0). The Prép can be empty. The same construction is obtained by ap-               |
|                            | plying an anomalous passivization, then extraposition, and possibly an             |
|                            | erasement of Prép N2   |
| (binary)                   | Example : Max a contribué au désordre = Il a été contribué au désordre             |
|                            | (E+par Max); Max a parlé de ce film à Léa = Il a été parlé de ce film              |
|                            | (E+par Max); Max a conclu ces corollaires d'un théorème = Il a été                 |
|                            | conclu ces corollaires (E+par Max)   |
| il être Vpp Prép N2 (E+par | Passive extraposition with $N2$ and without $N1$ , i.e. $N0\ V\ W=il$ être         |
| N0)                        | Vpp Prép N2 (E+par N0). The same form is obtained by applying an                   |
|                            | erasement of N1, an anomalous passivization, then extraposition                    |
| (binary)                   | Example : Le ministre a discuté de quelque chose avec les syndicats = Il           |
|                            | a été discuté avec les syndicats (E+par le ministre)                               |
| il V Prép N1 N0 =: il V    | The extraposed subject can be an infinitive clause introduced by the               |
| Prép N1 de V1c-inf W       | preposition $de$ , with an implicit subject coreferent with a nominal post-        |
|                            | modifier of a nominal object N1  |
| (binary)                   | Example : Il cadre avec les plans de Paul de nous être agréable                    |

TABLE E.3: Documentation des propriétés des tables de verbes (3)

| Feature                    | Description of the feature  |
|----------------------------|---|
| il V Prép N1 N0 =: il V    | The extraposed subject can be an infinitive clause introduced by the          |
| Prép N1 de V1-inf W        | preposition de, with an implicit subject coreferent with an object N1         |
| 1                          |   |
| (binary)                   | Example: Il échoit à Paul de faire la vaisselle                               |
| il V Prép N1 N0 =: il V    | The extraposed subject can be a sentential complement in the indicative       |
| Prép N1 Qu Pind            | mood, and coexist with an object N1   |
| (binary)                   | Example : Il a filtré de la réunion que Luc est candidat                      |
| il V Prép N1 N0 =: il V    | The extraposed subject can be a sentential complement in the subjunc-         |
| Prép N1 Qu Psubj           | tive mood, and coexist with an object N1                                      |
| (binary)                   | Example : Il arrive à Max qu'on le prenne pour un autre                       |
| il V Qu P W                | The subject can take the form of a sentential complement and be extra-        |
|                            | posed, i.e. shift to a complement position while expletive $il$ is introduced |
|                            | in subject position; the sentence has a metaphorical meaning                  |
| (binary)                   | Example : Il étincelle dans le regard de Luc qu'il est amoureux               |
| il y avoir V-n entre N0 et | Sentence with noun-centered argument structure, with il y avoir, a dever-     |
| N1                         | bal noun related with V, and the preposition entre before a conjunction       |
|                            | of NO and N1  |
| (binary)                   | Example: $Paul\ lutte\ avec\ Luc=Il\ y\ a\ une\ lutte\ entre\ Paul\ et\ Luc$  |
| il y avoir V-n entre N0 et | Form of a deverbal noun related with V, used in a sentence with noun-         |
| N1 (forme V-n)             | centered argument structure, with il y avoir, the deverbal noun, and the      |
|                            | preposition entre before a conjunction of NO and N1                           |
| (lexical)                  | Example: lutte  |
| il y avoir V-n entre N1 et | Sentence with noun-centered argument structure, with il y avoir, a dever-     |
| N2                         | bal noun related with V, and the preposition entre before a conjunction       |
|                            | of N1 and N2  |
| (binary)                   | Example : J'ai choqué mon verre contre celui de Max = Il y a eu choc          |
|                            | entre mon verre et celui de Max   |
| il y avoir V-n entre N1 et | Form of a deverbal noun related with V, used in a sentence with noun-         |
| N2 (forme V-n)             | centered argument structure, with il y avoir, the deverbal noun, and the      |
| ,                          | preposition entre before a conjunction of N1 and N2                           |
| (lexical)                  | Example: choc   |
| impératif => subj          | The sentential complement is in the subjunctive when the sentence ex-         |
| ,                          | presses an order  |
| (binary)                   | Example : Je crie que Paul vienne (cf. Je crie que Paul vient)                |
| Loc N1 = ici               | A locative object Loc N1 can be pronominalized into <i>ici</i>                |
| (binary)                   | Example : Paul entre ici  |
| Loc N1 = là                | A locative object Loc N1 can be pronominalized into $l\dot{a}$                |
| (binary)                   | Example: Paul monte là  |
| Loc N1 = Ppv               | Clitic pronominalization of a locative object Loc N1                          |
| (binary)                   | Example: Cette idée trotte dans sa tête = Cette idée y trotte                 |
| Loc N1 = Ppv =: en         | Clitic pronominalization of a locative object Loc N1 into en                  |
| (binary)                   | Example: Deux poussins ont éclos d'un même oeuf = Deux poussins en            |
| (billary)                  | ont éclos   |
| Loc N1 = Ppv =: y          | Clitic pronominalization of a locative object Loc N1 into $y$                 |
|                            | Example: On s'écrase dans le métro = On s'y écrase                            |
| (binary) Loc N1 =: à N1    | The preposition of a locative object Loc N1 can be $\dot{a}$                  |
|                            |   |
| (binary)                   | Example: Paul se précipite à la boulangerie                                   |
| Loc N1 =: à N1 destination | The preposition of a locative object Loc N1, interpreted as a destination,    |
| (1. :)                     | can be $\dot{a}$  |
| (binary)                   | Example : Le sang afflue à sa tête  |

Table E.4: Documentation des propriétés des tables de verbes (4)

| Feature                    | Description of the feature   |
|----------------------------|--|
| Loc N1 =: contre N1        | The preposition of a locative object Loc N1 can be contre                  |
| (binary)                   | Example: Le volet bat contre le mur  |
| Loc N1 =: contre N1 desti- | The preposition of a locative object Loc N1, interpreted as a destination, |
| nation                     | can be contre  |
| (binary)                   | Example : Max a cartonné contre un pin avec la voiture                     |
| Loc N1 =: dans N1          | The preposition of a locative object Loc N1 can be dans                    |
| (binary)                   | Example: Paul plonge dans l'eau  |
| Loc N1 =: dans N1 desti-   | The preposition of a locative object Loc N1, interpreted as a destination, |
| nation                     | can be $dans$  |
| (binary)                   | Example : L'auto dérape dans le fossé                                      |
| Loc N1 =: de N1            | The preposition of a locative object Loc N1 can be $de$                    |
| (binary)                   | Example: Paul rentre de la boulangerie. Paul s'approche de la boulan-      |
| (Sincery)                  | gerie  |
| Loc N1 =: de N1 source     | The preposition of a locative object Loc N1, interpreted as a source, can  |
| Loc IVI —. de IVI source   | be $de$  |
| (binary)                   | Example : Paul débouche du garage  |
| Loc N1 =: de V0-inf W      | A locative object Loc N1 can take the form of an infinitive clause inter-  |
| 200 NI —. GC VO-IIII VV    | preted as a source, taking the form de V0-inf W, with the preposition de   |
|                            | and an implicit subject coreferent with that of the main verb              |
| (binary)                   | Example: Paul revient de chercher du pain (Paul revient de la boulan-      |
| (biliary)                  | gerie)   |
| Loc N1 =: Loc N1 source,   | The preposition of a locative object Loc N1, interpreted as a source, can  |
| Loc # de                   | be other than $de$   |
| (binary)                   | Example : Luc est né dans une famille riche                                |
| Loc N1 =: Loc-source N1,   | The preposition of a stative locative object Loc N1 can be a source        |
| Loc-source # de            | preposition other than $de$  |
| (binary)                   | Example: Le fil pend au plafond  |
| Loc N1 =: par N1           | The preposition of a locative object Loc N1 can be par                     |
| (binary)                   | Example: $Luc\ a\ pris\ le\ couloir = Luc\ a\ pris\ par\ le\ couloir$      |
| Loc N1 =: sur N1           | The preposition of a locative object Loc N1 can be $sur$                   |
| (binary)                   | Example: De l'eau dégouline sur le toit                                    |
| Loc N1 =: sur N1 destina-  | The preposition of a locative object Loc N1, interpreted as a destination, |
| tion                       | can be $sur$   |
| (binary)                   | Example: Ce bas a déteint sur la robe                                      |
| Loc N1 =: vers N1          | The preposition of a locative object Loc N1 can be vers                    |
| (binary)                   | Example: Cette maison regarde vers le nord                                 |
| Loc N1 =: vers N1 destina- | The preposition of a locative object Loc N1, interpreted as a destination, |
| tion                       | can be vers  |
| (binary)                   | Example : Le bateau dérive vers la côte                                    |
| Loc N2 = ici               | A locative object Loc N2 can be pronominalized into <i>ici</i>             |
| (binary)                   | Example: Il ramène Paul ici faire son numéro                               |
| Loc N2 = là                | A locative object Loc N2 can be pronominalized into $l\hat{a}$             |
| (binary)                   | Example : Il conduit Paul là prendre le bus                                |
| Loc N2 = Ppv =: en         | Clitic pronominalization of a locative object Loc N2 into en               |
| (binary)                   | Example: Max a abstrait son esprit des difficultés présentes = Max en      |
|                            | a abstrait son esprit  |
| Loc N2 = Ppv =: y          | Clitic pronominalization of a locative object Loc N2 into $y$              |
| (binary)                   | Example: L'eau coule du robinet dans l'évier = L'eau y coule du robinet;   |
|                            | On accepte les chiens dans ce restaurant = On y accepte les chiens         |
|                            | 1 g  |

Table E.5: Documentation des propriétés des tables de verbes (5)

| Feature                    | Description of the feature   |
|----------------------------|--|
| Loc N2 =: à N2             | The preposition of a locative object Loc N2 can be $\dot{a}$   |
| (binary)                   | Example: L'eau arrive aux genoux de Luc  |
| Loc N2 =: à N2 destination | The preposition of a locative object Loc N2, interpreted as a destination,   |
| Loc N2 —. a N2 destination | can be $\dot{a}$   |
| (hinam)                    |  |
| (binary) Loc N2 =: à Nhum  | Example: Paul greffe un oeil au rosier   |
|                            | A locative object Loc N2 can take the form à Nhum, denoting a person   |
| (binary)                   | Example: Paul envoie Marie au patron demander un formulaire; Paul  |
| I NO NI                    | encorde Léa au guide   |
| Loc N2 =: à N-hum          | A locative object Loc N2 can take the form à N-hum, with a non-human   |
| (1:                        | meaning  |
| (binary)                   | Example : Paul envoie Marie à la boulangerie chercher des croissants   |
| Loc N2 =: autour de N2     | The preposition of a locative object Loc N2 can be autour de   |
| (binary)                   | Example: Paul conserve la main autour du manche  |
| Loc N2 =: autour de N2     | The preposition of a locative object Loc N2, interpreted as a destination,   |
| destination                | can be autour de   |
| (binary)                   | Example: Paul enroule le fil autour du stylo   |
| Loc N2 =: contre N2        | The preposition of a locative object Loc N2 can be contre  |
| (binary)                   | Example: Max cale le lit contre le mur   |
| Loc N2 =: contre N2 desti- | The preposition of a locative object Loc N2, interpreted as a destination,   |
| nation                     | can be contre  |
| (binary)                   | Example: La balle rebondit contre le mur   |
| Loc N2 =: dans N2          | The preposition of a locative object Loc N2 can be dans  |
| (binary)                   | Example : Paul envoie Marie dans le désert chercher du sable   |
| Loc N2 =: dans N2 desti-   | The preposition of a locative object Loc N2, interpreted as a destination,   |
| nation                     | can be dans  |
| (binary)                   | Example : Paul a érigé une statue dans son jardin  |
| Loc N2 =: de N2            | The preposition of a locative object Loc $N2$ can be $de$  |
| (binary)                   | Example : Il ramène Paul du Brésil faire un show   |
| Loc N2 =: de N2 destina-   | The preposition of a locative object Loc N2, interpreted as a destination,   |
| tion                       | can be $de$  |
| (binary)                   | Example: Luc rapproche la bouteille du cendrier  |
| Loc N2 =: de N2 source     | The preposition of a locative object Loc N2, interpreted as a source, can  |
|                            | be de  |
| (binary)                   | Example : Luc éloigne la bouteille du cendrier   |
| Loc N2 =: Loc N2 source,   | The preposition of a locative object Loc N2, interpreted as a source, can  |
| Loc # de                   | be other than de   |
| (binary)                   | Example : Luc découpe une photo dans un journal, Luc saisit un livre   |
|                            | sur l'étagère, Luc boit à la bouteille   |
| Loc N2 =: sur lui1-même    | A locative object Loc N2 can take the form sur lui-même, where the   |
|                            | pronoun lui is coreferent to an object N1  |
| (binary)                   | Example : Le froid a recroquevillé la plante sur elle-même, On a lové le   |
|                            | filin sur lui-même   |
| Loc N2 =: sur N2           | The preposition of a locative object Loc N2 can be $sur$   |
| (binary)                   | Example: Luc étale le beurre sur la tartine  |
| Loc N2 =: sur N2 destina-  | The preposition of a locative object Loc N2, interpreted as a destination,   |
| tion                       | can be sur   |
| (binary)                   | Example : Paul débouche sur la place   |
| (~11101 J )                | The state of the s |

Table E.6: Documentation des propriétés des tables de verbes (6)

| Feature                    | Description of the feature  |
|----------------------------|---|
| Loc N2 =: vers N2          | The preposition of a locative object Loc N2 can be <i>vers</i> with a directional |
|                            | interpretation  |
| (binary)                   | Example: L'appartement donne vers le sud. Paul dirige son fusil vers la           |
| (Siliary)                  | cible   |
| Loc N2 =: vers N2 destina- | The preposition of a locative object Loc N2, interpreted as a destination,        |
| tion                       | can be <i>vers</i> with a directional interpretation                              |
| (binary)                   | Example: Paul titube vers la sortie. Luc lance la balle vers la porte             |
| Loc N3 = Ppv =: y          |   |
|                            | Clitic pronominalization of a locative object Loc N3 into y                       |
| (binary)                   | Example: Max conduit Ida de la cuisine dans le salon = Max l'y conduit            |
| Lanking the North American | de la cuisine   |
| Loc N3 =: à N3 destination | The preposition of a locative object Loc N3, interpreted as a destination,        |
| (1:                        | can be $\dot{a}$  |
| (binary)                   | Example : Max convie Luc à une soirée   |
| Loc N3 =: contre N3 desti- | The preposition of a locative object Loc N3, interpreted as a destination,        |
| nation                     | can be contre   |
| (binary)                   | Example : Le car serre le cycliste contre le trottoir; Luc empile les             |
|                            | chaises contre le mur   |
| Loc N3 =: dans N3 desti-   | The preposition of a locative object Loc N3, interpreted as a destination,        |
| nation                     | can be dans   |
| (binary)                   | Example : Le maître attroupe les enfants dans la cour ; On a interné              |
|                            | Alex dans un asile  |
| Loc N3 =: sur lui1-même    | A locative object Loc N3 can take the form sur lui-même, where the                |
|                            | pronoun $lui$ is coreferent to an object $N1$                                     |
| (binary)                   | Example : Paul a basculé l'armoire sur elle-même                                  |
| Loc N3 =: sur N3 destina-  | The preposition of a locative object $Loc\ N3$ , interpreted as a destination,    |
| tion                       | can be $sur$  |
| (binary)                   | Example : Max dépose Luc sur la place ; Paul concentre les rayons sur             |
|                            | la cible  |
| Loc N3 =: vers N3          | The preposition of a locative object $Loc N3$ can be $vers$ with a directional    |
|                            | interpretation  |
| (binary)                   | Example: On draine l'eau vers le canal  |
| Loc N3 =: vers N3 destina- | The preposition of a locative object $Loc\ N3$ , interpreted as a destination,    |
| tion                       | can be <i>vers</i> with a directional interpretation                              |
| (binary)                   | Example : Le général a replié ses soldats vers la plaine                          |
| N0 (E+Ppv) V               | Anaphorical erasement or clitic pronominalization of an object N1 with            |
| (Prép+Prép-adv)            | conservation of Prép or modification of Prép into an adverbial form               |
| (binary)                   | Example: Luc court après les honneurs = Luc court après; Luc court                |
|                            | après Marie = Luc lui court après; On a rogné sur le budget = On a                |
|                            | rogné dessus  |
| N0 =: chemin               | The subject can denote a path, in a sentence that describes a stative             |
|                            | situation where a person or thing can travel through the path                     |
| (binary)                   | Example : La jetée avance dans la mer ; La route longe la rivière                 |
| N0 =: idée, (N1+N2) =:     | The subject can denote an idea and the locative object noted $N1$ or $N2$         |
| esprit                     | a person's mind; the sentence has a metaphorical meaning                          |
| (binary)                   | Example : L'idée de s'en aller filtrait dans son esprit                           |
| N0 =: idée, N1 =: esprit   | The subject can denote an idea and the object N1 a person's mind; the             |
|                            | sentence has a metaphorical meaning   |
| (binary)                   | Example : Un flot d'idées ruisselait dans son esprit                              |

TABLE E.7: Documentation des propriétés des tables de verbes (7)

| Feature                | Description of the feature   |
|------------------------|--|
| N0 =: le fait Qu P     | The subject can take the form le fait que P, close to a sentential comple-   |
|                        | ment, and denote an abstract entity  |
| (binary)               | Example : Le fait que Paul vienne me perturbe                                |
| N0 =: Nhum             | The subject can denote a person, or an animal linguistically assimilated     |
|                        | to a person  |
| (binary)               | Example: Luc quitte la ville. L'ennemi quitte la ville                       |
| N0 =: N-hum            | The subject can denote an entity which is not a person, nor an animal        |
|                        | linguistically assimilated to a person                                       |
| (binary)               | Example : La voiture a croisé le camion ; Les fruits débordent sur les       |
|                        | $cute{etals}$  |
| N0 =: N-hum métaphore  | The subject can denote an entity which is not a person, nor an animal        |
|                        | linguistically assimilated to a person; the sentence has a metaphorical      |
|                        | meaning (N0 normally denotes obligatorily a person)                          |
| (binary)               | Example : Les nuages pérégrinent dans le ciel                                |
| N0 =: Nhum, (N1+N2) =: | The subject can denote a person and the locative object noted N1 or N2       |
| Nabs                   | an abstract entity; the sentence has a metaphorical meaning                  |
| (binary)               | Example : Paul chemine vers sa pensée  |
| N0 =: Nhum, N1 =: Nabs | The subject can denote a person and the locative object noted N1 an          |
|                        | abstract entity; the sentence has a metaphorical meaning                     |
| (binary)               | Example: Paul fouille dans sa mémoire  |
| N0 =: Nhum, N1 =: mot  | The subject can denote a person and the object N1 words; the sentence        |
|                        | has a metaphorical meaning   |
| (binary)               | Example: Paul vomit des insultes; Luc ingurgite mes paroles                  |
| N0 =: Nnc              | The insertion of the verb into an independently observable sentence does     |
|                        | not impose additional constraints on the subject                             |
| (binary)               | Example: $Il \ pleut = Il \ continue \ de \ pleuvoir$                        |
| N0 =: Nnr              | The subject can denote a person, a concrete object, an abstract entity,      |
|                        | or take the form of a sentential subject or an infinitive clause             |
| (binary)               |  |
|                        | nuie Marie   |
| No =: Npl obl          | The subject is obligatorily in the plural or has a collective interpretation |
| (binary)               | Example: Les missiles convergent sur la cible                                |
| N0 =: Qu P             | The subject can be a sentential subject                                      |
| (binary)               | Example : Que Marie vienne déplait à Luc                                     |
| N0 =: V1c-inf W        | The subject can be an infinitive clause with an implicit subject coreferent  |
|                        | with a nominal post-modifier of a nominal object N1                          |
| (binary)               | Example : Se présenter aux élections a germé dans la tête de Paul            |
| N0 =: V1-inf W         | The subject can be an infinitive clause with an implicit subject coreferent  |
|                        | with an object N1  |
| (binary)               | Example : Faire du yoga calme Max ; Avoir ce diplôme a bénéficié à           |
| No. No. : CM           | Luc  |
| N0 =: V2c-inf W        | The subject can be an infinitive clause with an implicit subject coreferent  |
| (1:                    | with a nominal post-modifier of a nominal object N2                          |
| (binary)               | Example : Avoir vu ça écarte de l'esprit de Paul de se présenter             |

Table E.8: Documentation des propriétés des tables de verbes (8)

| Feature                   | Description of the feature  |
|---------------------------|---|
| N0 =: V2-inf W            | The subject can be an infinitive clause with an implicit subject coreferent   |
|                           | with an object N2   |
| (binary)                  | Example : Avoir fait ça prouve à Luc qu'il est en forme                       |
| N0 =: V3-inf W            | The subject can be an infinitive clause with an implicit subject coreferent   |
|                           | with an object N3   |
| (binary)                  | Example: (no Example known)   |
| N0 =: Vi-inf W            | The subject can be an infinitive clause with an implicit subject coreferent   |
| 100 = . V1 IIII VV        | with the subject of a sentential complement N1                                |
| (binary)                  | Example : Être trop gros empêche Luc de passer dans le couloir                |
| N0 =: V-inf W             | The subject can be an infinitive clause                                       |
| (binary)                  | Example : Faire ce genre de truc pèche contre le bon sens                     |
| N0 avoir V-n pour N1      | Sentence with noun-centered argument structure, with the same subject,        |
|                           | the verb <i>avoir</i> , a deverbal noun related with V, and an object pour N1 |
| (binary)                  | Example: Paul a de l'admiration pour Marie                                    |
| NO avoir V-n pour N1      | Form of a deverbal noun related with V, used in a sentence with noun-         |
| (forme V-n)               | centered argument structure, with the same subject, the verb avoir, the       |
|                           | deverbal noun, and an object pour N1  |
| (lexical)                 | Example: admiration   |
| N0 dé-V N1 Loc N3 nv-dest | Sentence with the same subject, a verb derived from V with a nega-            |
|                           | tive prefix, the same object N1 and a locative object N3, interpreted as      |
|                           | a new destination; the locative object N2 of the basic construction is        |
|                           | interpreted as a source in this one   |
| (binary)                  | Example : On a bobiné le fil sur un crayon; On a débobiné le fil sur le       |
|                           | lit   |
| N0 dé-V N1 Prép N2 source | Sentence with the same subject, a verb derived from V with a negative         |
|                           | prefix, the same object N1 and the same locative object N2, interpreted       |
|                           | as a source and possibly introduced by another preposition                    |
| (binary)                  | Example : On charge les caisses sur la remorque = On décharge les             |
|                           | caisses de la remorque  |
| N0 donner à N1 (une appa- | Paraphrase of the form N0 donner une apparence Vpp à N1, or N0 donner         |
| rence Vpp+l'apparence de  | une apparence de V-n à N1, where V-n is a deverbal noun related to V          |
| V-n)                      |   |
| (binary)                  | Example: Ce colorant argente les cheveux = Ce colorant donne aux              |
|                           | cheveux l'apparence de l'argent = Ce colorant donne aux cheveux une           |
|                           | apparence argentée  |
| N0 donner à N1 (une appa- | Form of a deverbal noun related with V, used in a paraphrase of the           |
| rence Vpp+l'apparence de  | form N0 donner une apparence Vpp à N1, or N0 donner une apparence de          |
| V-n) (forme V-n)          | V-n à N1  |
| (lexical)                 | Example: argent   |
| NO donner V-n à N1        | Paraphrase of the form NO donner V-n à N1, where V-n is a deverbal            |
|                           | noun related to V   |
| (binary)                  | Example : Paul a armé Luc = Paul a donné une arme à Luc ; Luc a               |
|                           | daté le vase du premier siècle = Luc a donné une date au vase                 |

TABLE E.9: Documentation des propriétés des tables de verbes (9)

| ect, V, and no                     |
|------------------------------------|
| ect, V, and no                     |
| ect, V, and no                     |
| ect, V, and no                     |
| , ,                                |
|                                    |
|                                    |
| ct, V, and the                     |
| = Max et Luc                       |
| e same subject,                    |
| ed with V, and                     |
| anandanaa ayaa                     |
| spondance avec                     |
| ence argument                      |
| ence argument osition $en$ , the   |
| osmon en, me                       |
|                                    |
| the same sub                       |
| the same sub-                      |
| with suffix -eur                   |
| · 1\ T                             |
| eci modère Luc                     |
| the same sub-<br>ith suffix -able, |
| . 1/1 . 11                         |
| est délectable                     |
| n the same sub-                    |
| Y with suffix                      |
| stille = La pâte                   |
| •                                  |
| the same sub-                      |
| rith suffix -ant,                  |
| escargots sont                     |
| <b>J</b>                           |
| the same sub-                      |
| rith suffix -ant,                  |
|                                    |
| menaçant pour                      |
|                                    |

Table E.10: Documentation des propriétés des tables de verbes (10)

| Feature                 | Description of the feature   |
|-------------------------|--|
| N0 être V-ant Prép      | Sentence with adjective-centered argument structure, with the same sub-  |
| (N1+N2)                 | ject, the verb être, a deverbal adjective related with V with suffix -ant,   |
|                         | and the object noted Prép N1 or Prép N2  |
| (binary)                | Example : Le soleil décline sur l'horizon = Le soleil est déclinant sur  |
|                         | l'horizon  |
| N0 être V-ant Prép N1   | Sentence with adjective-centered argument structure, with the same sub-  |
|                         | ject, the verb être, a deverbal adjective related with V with suffix -ant,   |
|                         | and the object Prép N1   |
| (binary)                | Example : Ida dépend de Max = Ida est dépendante de Max  |
| N0 être V-ant W         | Sentence with adjective-centered argument structure, with the same sub-  |
|                         | ject, the verb être, a deverbal adjective related with V with suffix -ant,   |
|                         | and sometimes a prepositional object Prép N1   |
| (binary)                | Example : $Ce \ truc \ énerve \ Luc = Ce \ truc \ est \ énervant \ pour \ Luc$   |
| N0 être V-eux W         | Sentence with adjective-centered argument structure, with the same sub-  |
|                         | ject, the verb <i>être</i> , a deverbal adjective related with V with suffix -eux,   |
|                         | and sometimes a prepositional object Prép N1   |
| (binary)                | Example : Cette solution désavantage Paul = Cette solution est   |
| No. o. v                | désavantageuse (E+pour Paul)   |
| N0 être V-n             | Sentence with noun-centered argument structure, with the same subject,   |
| (1.                     | the verb $\hat{e}tre$ , and a deverbal noun related with $V$   |
| (binary)                | Example : $Luc\ a\ escroqu\'e\ Max = Luc\ est\ un\ escroc$   |
| N0 être V-n (forme V-n) | Form of a deverbal noun morphologically associated with V, used in a   |
|                         | sentence with noun-centered argument structure, with the same subject,   |
| (1:1)                   | the verb <i>être</i> , and the deverbal noun   |
| (lexical)               | Example: escroc  |
| N0 être Vpp             | Sentence with the same subject, the verb <i>être</i> , the past participle of V; the sentence has a stative interpretation |
| (binary)                | Example: L'arbre penche vers le sol = L'arbre est penché; L'oiseau   |
| (biliary)               | $s'envole\ de\ son\ perchoir = L'oiseau\ est\ envolé$  |
| N0 être Vpp W           | Sentence with the same subject, the verb être, the past participle of V,   |
| The case tipp to        | and the same complements; the sentence has a stative interpretation  |
| (binary)                | Example : Paul s'entête à ce que tout soit en ordre = Paul est entêté à  |
|                         | ce que tout soit en ordre; Paul se décide à travailler = Paul est décidé   |
|                         | à travailler; Paul s'empresse de partir = Paul est empressé de partir  |
| N0 faire le V-n de N1   | Sentence with noun-centered argument structure, with the same subject,   |
|                         | the verb faire, the determiner $le$ , a deverbal noun related with $V$ , and an  |
|                         | object de N1   |
| (binary)                | Example: Paul pastiche le style de Luc = Paul fait le pastiche du style  |
|                         | de Luc   |
| NO faire le V-n de N1   | Form of a deverbal noun morphologically associated with V, used in a   |
| (forme V-n)             | sentence with noun-centered argument structure, with the same subject,   |
|                         | the verb <i>faire</i> , the determiner <i>le</i> , the deverbal noun, and an object de                                     |
|                         | N1   |
| (lexical)               | Example: pastiche  |
| N0 faire V-n Prép N1    | Paraphrase of the form N0 faire V-n Prép N1, where V-n is a deverbal   |
|                         | noun related to V and Prép a preposition   |
| (binary)                | Example: Paul assaisonne la salade = Paul fait l'assaisonnement de la  |
|                         | salade; Paul barre son chèque = Paul fait une barre sur son chèque; La   |
|                         | $fatigue\ cerne\ ses\ yeux=La\ fatigue\ fait\ des\ cernes\ à\ ses\ yeux$   |

Table E.11: Documentation des propriétés des tables de verbes (11)

| Feature                   | Description of the feature   |
|---------------------------|--|
| N0 faire le V-n Prép N1   | Form of a deverbal noun morphologically associated with V, used in a                               |
| (forme V-n)               | paraphrase of the form N0 faire V-n Prép N1, where Prép is a preposition                           |
| (lexical)                 | Example : assaisonnement   |
| N0 lancer V-n Loc N1      | Paraphrase of the form NO lancer V-n Loc N1, where V-n is a deverbal                               |
| Tro lancer v ii 200 ivi   | noun related to V and Loc a locative preposition   |
| (binary)                  | Example : On a torpillé le bateau = On a lancé une torpille sur le bateau                          |
| N0 lancer V-n Loc N1      | Form of a deverbal noun morphologically associated with V, used in a                               |
| (forme V-n)               | paraphrase of the form NO lancer V-n Loc N1, where Loc is a locative                               |
| (Tornic V II)             | preposition  |
| (lexical)                 | Example: torpille  |
| NO lieu de destination de | The subject is interpreted as the destination of the referent of N1. The                           |
|                           |  |
| N1                        | criterion to be applied is that of support sentences as in Boons <i>et al.</i>                     |
| (1:                       | (1976b) (p. 205) and in Guillet et Leclère (1992) (p. 22)  |
| (binary)                  | Example : Max tire la corde à lui; Paul se tape une bière; Paul a                                  |
|                           | réceptionné le colis   |
| N0 lieu de destination de | The subject is interpreted as the destination of the referent of N2. The                           |
| N2                        | criterion to be applied is that of support sentences as in Boons et al.                            |
|                           | (1976b) (p. 205) and in Guillet et Leclère (1992) (p. 22)  |
| (binary)                  | Example : Luc dépouille Léa de ses biens   |
| N0 lieu source de N1      | The subject is interpreted as the source of the referent of N1. The crite-                         |
|                           | rion to be applied is that of support sentences as in Boons et al. (1976b)                         |
|                           | (p. 205) and in Guillet et Leclère (1992) (p. 22)  |
| (binary)                  | Example : Luc catapulte la balle dans les airs ; Max congédie Paul                                 |
| NO lieu statique de N1    | The subject is interpreted as a place where the referent of an object N1                           |
|                           | is before, during and after the process. The criterion to be applied is that                       |
|                           | of support sentences as in Boons et al. (1976b) (p. 205) and in Guillet                            |
|                           | et Leclère (1992) (p. 22)  |
| (binary)                  | Example : Luc arbore une cravate   |
| N0 lui V Loc (N1pc+N2pc)  | Pronominalization of a noun which denotes a person and is a post-                                  |
|                           | modifier of a locative object, denoting a body part and noted Loc N1 or                            |
|                           | Loc N2; the pronoun is a dative clitic   |
| (binary)                  | Example : La balle a ricoché sur la poitrine de Luc = La balle lui a                               |
| (~                        | ricoché sur la poitrine  |
| N0 lui V Loc N1pc         | Pronominalization of a noun which denotes a person and is a post-                                  |
| Tto fair v Zoe Hipe       | modifier of a locative object Loc N1 denoting a body part; the pronoun                             |
|                           | is a dative clitic   |
| (binary)                  | Example : De l'eau dégouline sur la tête de Luc = De l'eau lui dégouline                           |
| (billary)                 | $sur\ la\ t\hat{e}te$  |
| N0 lui V N1 Loc N3pc      | Pronominalization of a noun which denotes a person and is a post-                                  |
| INO IUI V INI LOC INSPC   | modifier of a locative object Loc N3 denoting a body part and interpreted                          |
|                           | as a destination; the pronoun is a dative clitic   |
| (hinary)                  |  |
| (binary)                  | Example : Paul empile des assiettes sur la tête de Luc = Paul lui empile des assiettes sur la tête |
|                           | ues assieiles sur la lele  |

Table E.12: Documentation des propriétés des tables de verbes (12)

| Feature                   | Description of the feature   |
|---------------------------|--|
| N0 lui V N1pc W           | Pronominalization of a noun which denotes a person and is a post-                      |
| ·                         | modifier of an object N1 denoting a body part; the pronoun is a dative                 |
| !                         | clitic   |
| (binary)                  | Example : Le froid a rougi le nez de Paul = Le froid lui a rougi le                    |
|                           | nez; L'eau ballonne l'estomac de Luc = L'eau lui ballonne l'estomac;                   |
| !                         | L'obus a brisé le bras de Luc en trois = L'obus lui a brisé le bras en                 |
|                           | trois  |
| N0 lui V Prép N1pc        | Pronominalization of a noun which denotes a person and is a post-                      |
|                           | modifier of an object Prép N1 denoting a body part; the pronoun is                     |
|                           | a dative clitic  |
| (binary)                  | Example : Luc lorgne sur les seins de Marie = Luc lui lorgne sur les                   |
|                           | seins  |
| N0 mettre V-n Loc N1      | Paraphrase of the form N0 mettre V-n Loc N1, where V-n is a deverbal                   |
|                           | noun related to V and Loc a locative preposition                                       |
| (binary)                  | Example : Paul borne le pré = Paul met des bornes autour du pré                        |
| NO mettre V-n Loc N1      | Form of a deverbal noun morphologically associated with V, used in a                   |
| (forme V-n)               | paraphrase of the form N0 mettre V-n Loc N1, where Loc is a locative                   |
| (1011110 1 11)            | preposition  |
| (lexical)                 | Example: borne   |
| N0 mouvement              | The subject is interpreted as a moving object or place                                 |
| (binary)                  | Example : La balle a frôlé la cible  |
| N0 porter V-n à N1        | Sentence with noun-centered argument structure, with the same subject,                 |
|                           | the verb <i>porter</i> , a deverbal noun related with V, and an object à N1            |
| (binary)                  | Example: Paul porte une grande admiration à son chef                                   |
| N0 porter V-n à N1 (forme | Form of a deverbal noun related with V, used in a sentence with noun-                  |
| V-n)                      | centered argument structure, with the same subject, the verb <i>porter</i> , the       |
| ,                         | deverbal noun, and an object à N1  |
| (lexical)                 | Example: admiration  |
| No pousser V-n, $Sfx = E$ | Sentence with noun-centered argument structure, with the same subject,                 |
| , ,                       | the verb <i>pousser</i> , and a deverbal noun related with V with an empty suffix      |
| (binary)                  | Example: $Luc\ crie = Luc\ pousse\ un\ cri$  |
| No pousser V-n, Sfx =     | Sentence with noun-centered argument structure, with the same subject,                 |
| ment                      | the verb <i>pousser</i> , and a deverbal noun related with V with the suffix -         |
|                           | ment   |
| (binary)                  | Example: $Luc\ grogne = Luc\ pousse\ un\ grognement$                                   |
| N0 rendre N1 (E+plus) V-  | Sentence with the same subject, the verb rendre, the same object, some-                |
| adj                       | tines a comparative adverb, and a deverbal adjective related with $V$                  |
| (binary)                  | Example : $\hat{L}$ 'été a embelli le jardin = $L$ 'été a rendu le jardin ( $E$ +plus) |
|                           | beau; Ce produit a féminisé Max = Ce produit a rendu Max (E+plus)                      |
| 1                         | féminin  |
| N0 rendre N1 plus V-adj   | Sentence with the same subject, the verb rendre, the same object, a                    |
|                           | comparative adverb, and a deverbal adjective related with $V$                          |
| (binary)                  | Example : Le vent a abaissé la température = Le vent a rendu la                        |
|                           | température plus basse   |
| NO rendre N1 plus V-adj   | Form of a deverbal adjective related with V, used in a sentence with the               |
| (forme V-n)               | same subject, the verb <i>rendre</i> , the same object, a comparative adverb,          |
| 1                         | and the deverbal adjective   |
| (lexical)                 | Example: bas   |

Table E.13: Documentation des propriétés des tables de verbes (13)

| Feature                      | Description of the feature  |
|------------------------------|---|
| N0 rendre N1 V-adj           | Sentence with the same subject, the verb <i>rendre</i> , the same object, and a   |
|                              | deverbal adjective related with V   |
| (binary)                     | Example : Ce produit active la fermentation = Ce produit a rendu la   |
|                              | fermentation active   |
| N0 rendre N1 V-adj (forme    | Form of a deverbal adjective related with V, used in a sentence with  |
| V-n)                         | the same subject, the verb rendre, the same object, and the deverbal  |
| ,                            | adjective   |
| (lexical)                    | Example: actif  |
| NO V                         | Sentence with no objects, possibly by erasement of all the objects  |
| (binary)                     | Example : Paul dort; Paul flirte avec Marie = Paul flirte; Paul Luc a inventé que Marie était mariée / *Luc a inventé; Paul hésite à se |
|                              | $prononcer = Paul \ h\'esite$   |
| N0 V (Adj) (Qu P)            | Raising of two parts of a sentential complement : (i) Adj; (ii) an embed-   |
|                              | ded sentential subject  |
| (binary)                     | Example : Je juge qu'il est souhaitable que Léa vienne = Je juge sou-   |
|                              | haitable que Léa vienne   |
| N0 V (être Adj) (Qu P)       | Raising of two parts of a sentential complement : (i) être Adj; (ii) an   |
|                              | embedded sentential subject   |
| (binary)                     | Example : Je juge qu'il est souhaitable que Léa vienne = Je juge être   |
|                              | souhaitable que Léa vienne; Max lui dit être possible que Luc arrive  |
|                              | demain  |
| N0  V (N1  de  N1c) = N0  V  | A nominal direct object of the form N1 de N1c, where N1c is a nominal   |
| (N1c) (Prép N1)              | post-modifier, can be replaced by N1c and a prepositional modifier Prép   |
|                              | N1 called echo modifier (restructuration)   |
| (binary)                     | Example : Luc stimule la curiosité de Marie = Luc stimule Marie dans  |
| NO V (NO · NO) (F · I · NII) | sa curiosité  |
| N0 V (N2+N3) (E+de N1)       | Sentence where a locative object N2 or N3 is direct, by erasement of its  |
|                              | preposition, and an object $N1$ is erased or occurs with the preposition $de$   |
| (binary)                     | Example : On a exproprié l'immeuble de tous ces gens = On a exproprié   |
|                              | tous ces gens (E+de l'immeuble); On a infiltré 3 agents dans le réseau = On a infiltré le réseau (E+de 3 agents)                        |
| N0 V à N1                    | Sentence with an object à N1, possibly by erasement of other objects  |
| (binary)                     | Example: $Max \ ment \ à \ Luc$ ; $Qa \ a \ abouti \ pour \ Paul \ à \ un \ échec = Qa \ a$   |
|                              | abouti à un échec   |
| NO V à N1 Prép N2            | Sentence with a sentential complement with the preposition $\hat{a}$ and ano-   |
| · · · · · - · · · -          | ther object noted Prép N2   |
| (binary)                     | Example: Travailler plus revient pour Luc à ce qu'il gagne plus   |
| N0 V à N2                    | Sentence with an object à N2, by erasement of an object N1  |
| (binary)                     | Example: Luc a répondu à Paul qu'il pleut = Luc a répondu à Paul;   |
|                              | abla a contraint Luc à des sacrifices = Ca contraint à des sacrifices   |
| N0 V à N2 : 'P'              | The sentential complement N1 can take the form of direct speech   |
| (binary)                     | Example : $Paul\ crie\ \grave{a}\ Marie\ qu'elle\ est\ idiote = Paul\ crie\ \grave{a}\ Marie\ :\ "Tu$                                   |
|                              | es idiote"  |
| N0 V Adv                     | The object N1 can take the form of an adverb  |
| (binary)                     | Example : Le film dure 3 heures = Le film dure longtemps. Le sac pèse   |
|                              | 10  kg = le sac pèse lourd  |
| N0 V après Nhum              | Sentence with the same subject, the verb V, and an object après Nhum  |
| -                            | denoting a person   |
| (binary)                     | Example: Max gueule après sa femme  |

Table E.14: Documentation des propriétés des tables de verbes (14)

| Feature                   | Description of the feature   |
|---------------------------|--|
| N0 V contre Nhum          | Sentence with the same subject, the verb V, and an object contre Nhum      |
|                           | denoting a person  |
| (binary)                  | Example : Paul râle contre les syndicats                                   |
| NO V dans N1              | Sentence with the same subject, the verb V, and a nominal object with      |
| TTO T GUILD ITE           | the preposition dans   |
| (binary)                  | Example: Paul persiste dans ses convictions                                |
| NO V de NOpc              | Sentence with the same subject denoting a concrete thing or a person,      |
|                           | the verb V, and an object with the preposition de denoting a part of the   |
|                           | concrete thing or of the body of the person                                |
| (binary)                  | Example: Paul souffre du bras droit; Le vélo dérape de la roue avant       |
| N0 V de N0pc W            | With a subject denoting a concrete thing or a person, additional object    |
|                           | with the preposition $de$ denoting a part of the concrete thing or of the  |
|                           | body of the person   |
| (binary)                  | Example: La voiture enfonce dans la boue de la roue avant gauche; Luc      |
| (Silicity)                | presse du doigt sur le bouton  |
| N0 V de N1                | Sentence with an object de N1, possibly by erasement of other objects      |
| (binary)                  | Example: Max profite du soleil; Paul parle du soleil à Marie = Paul        |
| (Silicity)                | parle du soleil  |
| NO V de N1 Prép N2        | Sentence with a sentential complement with the preposition de and ano-     |
| 110 V de 111 1 10p 112    | ther object noted Prép N2  |
| (binary)                  | Example : Luc parle à Marie de ce qu'il pourrait partir en vacances        |
| N0 V Loc N1               | Sentence with a locative object Loc N1, possibly by erasement of other     |
| 110 7 200 111             | objects or by insertion of a locative preposition                          |
| (binary)                  | Example: Les étoiles étincellent dans le ciel; Le bateau aborde au quai =  |
|                           | Le bateau aborde le quai; Max grimpe à l'échelle = Max grimpe l'échelle    |
| N0 V Loc N1 source        | Sentence with a locative object interpreted as a source, possibly by era-  |
|                           | sement of other objects  |
| (binary)                  | Example : Le train a déraillé de la voie ; La fumée sort de la cheminée    |
| N0 V Loc N1 destination   | Sentence with a locative object interpreted as a destination               |
| (binary)                  | Example: Max s'est effondré dans un fauteuil                               |
| N0 V Loc N1 Loc N2        | Stative sentence with two locative objects, the first with a source prepo- |
|                           | sition, and the second with a destination preposition                      |
| (binary)                  | Example : L'escalier descend de la cuisine à la cave                       |
| N0 V Loc N1 source Loc N2 | Sentence with two locative objects, the first interpreted as a source, and |
| destination               | the second as a destination  |
| (binary)                  | Example : Luc descend de la cuisine à la cave                              |
| N0 V Loc N1 V0-inf W      | Sentence with a nominal locative object and an infinitive clause with an   |
|                           | implicit subject coreferent with that of the main verb                     |
| (binary)                  | Example: Paul entre dans le bureau demander du feu; Paul grimpe à          |
|                           | l'échelle tailler le lierre  |
| N0 V Loc N2               | Sentence with a locative object Loc N2, by erasement of other objects      |
| (binary)                  | Example: Max descend Luc à la gare = Max descend à la gare; La ville       |
|                           | s'étend de la rivière jusqu'à la montagne = La ville s'étend jusqu'à la    |
|                           | montagne   |
| N0 V Loc N2 destination   | Sentence with a locative object Loc N2 interpreted as a destination place, |
|                           | by erasement of other objects  |
| (binary)                  | Example : L'eau cascade des rochers sur la vallée = L'eau cascade sur      |
|                           | la vallée  |
|                           |  |

Table E.15: Documentation des propriétés des tables de verbes (15)

| Feature                | Description of the feature  |
|------------------------|---|
| N0 V N0pc W            | The subject can denote a person, and the direct object, with the deter-         |
|                        | miner le, can denote a body part of the person                                  |
| (binary)               | Example : Max donne le bras à Léa ; Max approche la main du feu ; Max           |
|                        | bouge les oreilles  |
| N0 V N1                | Sentence with a direct object N1, possibly by erasement of other objects        |
| (binary)               | Example : Luc énerve Ida; Luc amène Marie au parc = Luc amène                   |
|                        | Marie ; Luc mène Marie au parc / *Luc mène Marie                                |
| N0 V N1 + 2            | Sentence with a direct object metonymically interpreted as both objects         |
| (binary)               | Example : Léa a boutonné un pan de sa robe avec l'autre = Léa a bou-            |
|                        | tonné sa robe   |
| N0 V N1 à ce Qu P      | An object à N2 can be a sentential complement                                   |
| (binary)               | Example : Paul voit que Luc est passé à ce qu'il y a une bouteille vide         |
| NO V N1 à N2           | Sentence with a direct object and an object à N2                                |
| (binary)               | Example : Luc a cédé ce livre à Marie   |
| NO V N1 à N2 de Nhum   | An additional object with de as its preposition denotes a person obligato-      |
|                        | rily also referred to by an element of the object N1 (projection constraint     |
|                        | in the sense of Gross (1975))   |
| (binary)               | Example : Paul dit à Marie de Luc qu'il est génial, cf. Voici Luc dont          |
| ,                      | Paul dit à Marie qu'il est génial   |
| NO V N1 à N2 Dnum      | An additional direct complement, which takes the form of a cardinal             |
| Nmonnaie               | numeral and a currency name, denotes a sum of money                             |
| (binary)               | Example : Paul a facturé ce livre 100 francs à Luc                              |
| NO V N1 à N2 pour Dnum | An additional object, with the preposition <i>pour</i> , a cardinal numeral and |
| Nmonnaie               | a currency name, denotes a sum of money   |
| (binary)               | Example : Luc a cédé ce livre à Marie pour 60 francs                            |
| N0 V N1 comme N2       | A direct object N2 can be introduced by comme                                   |
| (binary)               | Example : On a élu Paul président = On a élu Paul comme président               |
| N0 V N1 contre N2hum   | An additional object of the form contre N2 denotes a person                     |
| (binary)               | Example : Cette décision révolte Luc contre le gouvernement                     |
| NO V N1 de coup de V-n | An additional modifier of the form de coup de V-n, denoting a blow,             |
| ·                      | contains a deverbal noun related to the verb V and denotes an instrument        |
| (binary)               | Example : Luc a fouetté Léa de coups de fouet; Léa a poignardé Luc              |
|                        | d'un coup de poignard   |
| NO V N1 de coup de V-n | Form of a deverbal noun morphologically associated with V, used in an           |
| (forme V-n)            | additional modifier of the form de coup de V-n, denoting a blow, that           |
|                        | contains the deverbal noun and denotes an instrument                            |
| (lexical)              | Example: $fouet$  |
| N0 V N1 de N2          | Sentence with a direct object and an object de N2                               |
| (binary)               | Example : Léa accuse Max de viol ; Paul a alourdi son sac d'un gros livre       |
| N0 V N1 de N2 source   | Sentence with a direct object and a locative object de N2 interpreted as        |
|                        | a source, possibly by erasement of other objects                                |
| (binary)               | Example : Paul a collecté les informations de ce thésaurus ; Paul perçoit       |
|                        | ce salaire d'une PME; Paul déplace le pion de la case 5                         |

Table E.16: Documentation des propriétés des tables de verbes (16)

| Feature                       | Description of the feature  |
|-------------------------------|---|
| N0 V N1 de N2hum              | An additional object with de as its preposition denotes a person obligato-  |
| 112 112 22 11212              | rily also referred to by an element of the object N1 (projection constraint)  |
| (binary)                      | Example: Paul sait de Marie qu'elle est partie, cf. Marie dont Paul sait  |
| (**, /                        | qu'elle est partie; Paul aime de Marie qu'elle s'énerve, cf. Marie dont   |
|                               | Paul aime qu'elle s'énerve  |
| NO V N1 de N2 matériau        | Sentence with a direct object and an object de N2 denoting material for   |
|                               | the process   |
| (binary)                      | Example : Paul a bâti cette cabane seulement de planches usagées  |
| N0  V  N1  de  N2 = N0  enle- | Sentence of the form N0 V N1 de N2 paraphrased by N0 enlever N2 de  |
| ver N2 de N1                  | N1  |
| (binary)                      | Example : Ce procédé épure les eaux de leurs germes = Ce procédé enlève   |
|                               | leurs germes des eaux; Luc a purgé ce radiateur d'un peu d'air = Luc a  |
|                               | enlevé un peu d'air de ce radiateur   |
| N0 V N1 de N2 = N0            | Sentence of the form N0 V N1 de N2 paraphrased by N0 mettre N2 Loc  |
| mettre N2 Loc N1              | N1  |
| (binary)                      | Example: Paul a alourdi son sac d'un gros livre = Pierre a mis un gros  |
|                               | livre dans son sac; Luc orne la table de fleurs = Luc met des fleurs sur  |
|                               | la table  |
| N0 V N1 de N3 attache         | Sentence with a direct object and a complement de N3 attache, introdu-  |
|                               | ced by the preposition $de$ , denoting a tying system and interpreted as an   |
|                               | instrument  |
| (binary)                      | Example : Luc a boulonné les planches de 4 boulons  |
| N0 V N1 de N-hum              | Sentence with a direct object and acomplement introduced by the pre-  |
|                               | position $de$ and denoting a non-human entity   |
| (binary)                      | Example: Luc appelle son fils d'un surnom   |
| N0 V N1 de V-n                | An additional complement of the form de V-n contains a deverbal noun  |
|                               | related to the verb V   |
| (binary)                      | Example : Paul a giflé Léa de 3 baffes; Luc surnomme sa fille d'un  |
| NO V/ NII 1 V/ /C             | surnom ridicule   |
| N0 V N1 de V-n (forme V-      | Form of a deverbal noun morphologically associated with V, used in an   |
| n)                            | additional complement of the form de V-n  |
| (lexical)                     | Example: baffe  |
| N0 V N1 destination           | A locative object N1 interpreted as a destination can become a direct   |
| (himama)                      | object, by erasement of the preposition introducing N1  |
| (binary)<br>N0 V N1 en N2     | Example: Max farfouille dans le tiroir = Max farfouille le tiroir   |
| (binary)                      | Sentence with a direct object and an object en N2<br>Example : Paul a empilé les dossiers en un gros tas ; Luc a transformé |
| (Omary)                       | ce taudis en un palais; Luc a scié la planche en deux bouts   |
| N0 V N1 entre N2pl obl        | Sentence with a direct object and an object entre N2, where N2 is in the  |
| 140 V 141 CHE 142 PI ODI      | plural or a conjunction of several noun phrases   |
| (binary)                      | Example: Paul répartit les dossiers entre Luc et Max  |
| N0 V N1 et N2                 | Two objects N1 and N2 can be coordinated without preposition  |
| (binary)                      | Example : Luc lace le côté droit et le côté gauche ; Le maire marie Max   |
| ()                            | et Léa  |
| N0 V N1 Loc N1pc W            | An object N1 can denote a person or a concrete object and coexist with  |
|                               | an additional locative object Loc N1pc denoting a body part of the person   |
|                               | or a part of the concrete object  |
| (binary)                      | Example : Ida masse Luc à la jambe ; Le chirurgien quadrille le patient   |
|                               | en 9 régions sur la poitrine  |
| L                             |   |

Table E.17: Documentation des propriétés des tables de verbes (17)

| Feature                              | Description of the feature   |
|--------------------------------------|--|
| N0 V N1 Loc N2                       | Sentence with a direct object and a locative object Loc N2                             |
| (binary)                             | Example : On a érigé une statue derrière le poteau                                     |
| NO V N1 Loc N2 destina-              | Sentence with a direct object and a locative object interpreted as a                   |
| tion                                 | destination place  |
| (binary)                             | Example : Luc glisse la lettre dans la fente   |
| N0 V N1 Loc N2 source                | Sentence with a direct object and a locative object interpreted as a source            |
|                                      | place  |
| (binary)                             | Example: Luc raye deux noms dans la liste  |
| N0 V N1 Loc N2 source Loc            | Sentence with a direct object and two locative objects, the first being                |
| N3 destination                       | interpreted as a source place and the second as a destination place                    |
| (binary)                             | Example : Luc chasse la bille du trou dans la rainure ; Luc déménage les               |
|                                      | meubles du salon dans la soupente  |
| N0 V N1 Loc N2 source,               | Sentence with a direct object and an object interpreted as a source place,             |
| Loc # de                             | but introduced by a preposition other than $de$  |
| (binary)                             | Example : Paul recense deux célibataires dans la liste ; Paul grappille des            |
|                                      | informations dans les journaux   |
| N0 V N1 Loc N2 V1-inf W              | Sentence with a direct object N1, a nominal locative object and an infi-               |
|                                      | nitive clause with an implicit subject coreferent with N1                              |
| (binary)                             | Example: Paul envoie Marie dans le bureau demander du feu                              |
| NO V N1 Loc N2 matériau,             | Sentence with a direct object and a locative object denoting material for              |
| Loc # de                             | the process, but introduced by a locative preposition other than de                    |
| (binary)                             | Example: Paul a sculpté un ange dans le marbre   |
| N0 V N1 Loc N2pc, destination de N2c | A locative object Loc N2, interpreted as a destination, can have a nominal             |
| nation de N2C                        | post-modifier de N2c which denotes a person while N2 denotes a body part of the person |
| (binary)                             | Example : Paul a tatoué une fleur sur l'épaule de Marie                                |
| N0 V N1 Loc N2texte des-             | The object N2 can denote a text and be interpreted as a destination;                   |
| tination                             | the sentence has a metaphorical meaning  |
| (binary)                             | Example: Paul a bâti une série d'hypothèses dans son bouquin                           |
| N0 V N1 Loc N3 destina-              | Sentence with a direct object and a locative object Loc N3 interpreted as              |
| tion                                 | a destination, by erasement of the locative object interpreted as a source             |
| (binary)                             | Example : Max a accompagné Luc chez lui  |
| N0 V N1 Loc N-hum                    | Sentence with a direct object and a locative object Loc N, which has a                 |
|                                      | locative preposition, and is interpreted as a source place or as a destina-            |
|                                      | tion place   |
| (binary)                             | Example: Luc flanque un coup sur la table (cf. Luc flanque un coup à                   |
|                                      | Paul); Luc barbote 100 F dans la caisse (cf. Luc barbote 100 F à Paul);                |
|                                      | On a nommé Paul à ce poste   |
| N0 V N1 N2                           | Sentence with two direct objects   |
| (binary)                             | Example: Luc appelle son fils Paul   |
| N0 V N1 Prép N2                      | Sentence with a direct object N1 and a prepositional object Prép N2,                   |
|                                      | possibly by erasement of a preposition introducing N1                                  |
| (binary)                             | Example: Paul tient cela de Luc  |
| NO V N1 Prép N2 contre               | An additional complement with the preposition <i>contre</i> denotes a person           |
| Nhum                                 |  |
| (binary)                             | Example : Luc s'accorde avec Marie contre Luc à forger des preuves                     |

Table E.18: Documentation des propriétés des tables de verbes (18)

| Feature  | Description of the feature  |
|--|---|
| N0 V N1 Prép N2 Prép N3  | Sentence with a direct object N1 and two prepositional objects  |
| (binary)   | Example: Max traduit ce texte de l'anglais au turc  |
| N0 V N1 source   | A locative object N1 interpreted as a source can become the unique  |
|  | object and a direct object, by erasement of other objects and of the  |
| (1:  | preposition introducing N1  |
| (binary) N0 V N1 sur N1pc  | Example: Max a déserté de son régiment = Max a déserté son régiment   |
| NO V IVI SUI IVIPC   | Sentence with a direct object denoting a person or a concrete object, and a locative object denoting a body part of the person or a part of               |
|  | the concrete object, and introduced by the preposition sur. The locative  |
|  | object indicates which part of the body or concrete object is concerned   |
|  | by the locative relation. The prepositional object present in the basic   |
|  | construction is absent from this one  |
| (binary)   | Example: Max allonge Marie sur le dos; Max dispose les livres sur la  |
| No. V. N. d. V. C. N. C. | tranche   |
| N0 V N1 V0-inf W   | Sentence with a nominal direct locative object and a non-prepositional  |
|  | infinitive clause with an implicit subject coreferent with that of the main verb  |
| (binary)   | Example : Paul traverse la rue acheter du pain  |
| N0 V N1 V1-inf W   | Sentence with a nominal direct object and a non-prepositional infinitive  |
|  | clause with an implicit subject coreferent with the nominal object  |
| (binary)   | Example: Paul envoie Luc acheter du pain  |
| N0 V N1-hum  | Sentence with the same subject, the verb V, and a direct nominal object   |
|  | with a non-human meaning  |
| (binary)   | Example: Paul commence le tri des vis; Paul commence les vis; Paul  |
|  | choisit entre faire du ski et faire du saut = Paul choisit le ski ou le saut;<br>Paul choisit entre bombarder le pont et bombarder l'usine = Paul choisit |
|  | le pont ou l'usine  |
| NO V N1abs Loc   | Sentence with an object N1 denoting an abstract entity, and an object   |
| (N2abs+N3abs)  | Loc N2 or Loc N3 introduced by a locative preposition and denoting an   |
|  | abstract entity; the sentence has a metaphorical meaning  |
| (binary)   | Example : Luc collecte des exemples dans ses souvenirs ; Luc relègue ses  |
| No. V. N. d. L. N. D. L.   | rancunes dans les mauvais souvenirs   |
| N0 V N1abs Loc N2abs   | Sentence with an object N1 denoting an abstract entity, and an object Loc N2 introduced by a locative preposition and denoting an abstract                |
|  | entity; the sentence has a metaphorical meaning   |
| (binary)   | Example: Paul a adapté la théorie aux nouveaux faits  |
| N0 V N1c   | A nominal direct object N1 with a nominal post-modifier de N1c can be   |
|  | replaced by N1c alone (metonymic reduction)   |
| (binary)   | Example: Paul contrecarre les projets de Marie = Paul contrecarre Ma-   |
|  | rie; cf. Paul prévient tous les désirs de Marie/Paul prévient Marie   |
| NO V N1c à N1pc  | A nominal direct object of the form N1pc de N1c, where N1c denotes a  |
|  | person or a concrete object and N1pc denotes a body part of the person  |
|  | or a part of the concrete object, can be replaced by N1c and a locative   |
| (binary)   | object à N1pc (restructuration)<br>Example : La flèche a atteint le bras de Luc = La flèche a atteint Luc   |
| (Siliuly)  | au bras   |
|  |   |

Table E.19: Documentation des propriétés des tables de verbes (19)

| Feature                  | Description of the feature   |
|--------------------------|--|
| N0 V N1c par N1pc        | A nominal direct object of the form N1pc de N1c, where N1c denotes a     |
|                          | person or a concrete object and N1pc denotes a body part of the person   |
|                          | or a part of the concrete object, can be replaced by N1c and a locative  |
|                          | object par N1pc (restructuration)  |
| (binary)                 | Example: Luc a pris la main de Marie = Luc a pris Marie par la main      |
| NO V N1c sur N1pc        | A nominal direct object of the form N1pc de N1c, where N1c denotes a     |
| ·                        | person or a concrete object and N1pc denotes a body part of the person   |
|                          | or a part of the concrete object, can be replaced by N1c and a locative  |
|                          | object sur N1pc (restructuration)  |
| (binary)                 | Example : Luc a embrassé la joue de Marie = Luc a embrassé Marie sur     |
|                          | la joue  |
| N0 V N1hum               | Sentence with the same subject, the verb V, and a direct nominal object  |
|                          | denoting a person  |
| (binary)                 | Example: Paul choisit entre viser l'homme et viser l'arme = Paul choisit |
|                          | l'homme ou l'arme  |
| NO V N1hum de N2abs      | Sentence with an object N1 denoting a person, and a locative object de   |
|                          | N2 denoting an abstract entity; the sentence has a metaphorical meaning  |
| (binary)                 | Example : Paul a sorti Luc de ses problèmes; L'aube nous ensoleilla      |
|                          | d'espoir   |
| NO V N1hum Loc           | Sentence with an object N1 denoting a person, and a locative object      |
| (N2abs+N3abs)            | Loc N2 or Loc N3 introduced by a preposition and denoting an abstract    |
| (                        | entity; the sentence has a metaphorical meaning                          |
| (binary)                 | Example : Ces épreuves rassemblent les habitants dans un destin com-     |
| ( = ====== 3 )           | mun  |
| N0 V N1hum Loc N2abs     | Sentence with an object N1 denoting a person, and a locative object      |
|                          | Loc N2 introduced by a preposition and denoting an abstract entity; the  |
|                          | sentence has a metaphorical meaning                                      |
| (binary)                 | Example : Cette action a gravé Paul dans les mémoires ; Son éducation    |
|                          | a enlisé Léa dans ses complexes  |
| NO V N1pc de N1c         | A direct object N1 can take the form N1pc de N1c, where N1c denotes a    |
|                          | person and N1pc denotes a body part of the person                        |
| (binary)                 | Example : Paul dessine le bras de Léa                                    |
| NO V N2                  | An object N2 can become the unique object and a direct object, by        |
|                          | erasement of other objects and possibly of the preposition introducing   |
|                          | N2   |
| (binary)                 | Example: Luc excuse Paul de ces maladresses = Luc excuse ces mal-        |
|                          | adresses; On a nommé Max ambassadeur = On a nommé un ambassa-            |
|                          | deur; Luc rallie des mercenaires en une armée = Luc rallie une armée     |
| N0 V N2 (E+de N1 source) | Sentence where an object N2 is direct, by erasement of its preposition,  |
| (= , 43 354.66)          | and an object N1 denoting a source is erased or occurs with the prepo-   |
|                          | sition de  |
| (binary)                 | Example : J'ai débarrassé le grenier de toutes ces caisses = J'ai        |
| (                        | débarrassé toutes ces caisses du grenier                                 |
|                          | week   |

Table E.20: Documentation des propriétés des tables de verbes (20)

| Feature                   | Description of the feature   |
|---------------------------|--|
| N0 V N2 (E+de N1)         | Sentence where a locative object N2 is direct, by erasement of its prepo-            |
| ,                         | sition, and an object $N1$ is erased or occurs with the preposition $de$             |
| (binary)                  | Example: Luc livre du vin à Paul = Luc livre Paul $(E+de\ vin)$ ; Luc                |
|                           | emmanche un manche sur la pelle = Luc emmanche la pelle $(E+d'un)$                   |
|                           | manche); Luc asperge du vin sur le $mur = Luc$ asperge le $mur$ (E+de                |
|                           | vin)   |
| N0 V N2 (E+Loc N1 desti-  | Sentence where an object N2 is direct, by erasement of its preposition,              |
| nation)                   | and an object N1 denoting a place of destination is erased or occurs with            |
| nation)                   | a locative preposition   |
| (binary)                  | Example: Luc badigeonne le mur de noir = Luc badigeonne du noir                      |
|                           | sur le mur; Luc charge le camion de caisses = Luc charge des caisses                 |
|                           | $(E+sur\ le\ camion)$  |
| N0 V N2 (E+Loc N1)        | Sentence where an object N2 is direct, by erasement of its preposition,              |
| (2 + 250 112)             | and an object N1 denoting a place is erased or occurs with a locative                |
|                           | preposition  |
| (binary)                  | Example: Luc coupe le pain en dix tranches = Luc coupe dix tranches                  |
| (Siliary)                 | $(E+dans\ le\ pain)$ ; $Max\ cultive\ son\ champ\ en\ bl\'e=Max\ cultive\ du\ bl\'e$ |
|                           | $(E+dans\ son\ champ)$   |
| N0 V N2 =: N0 V Qu Psubj  | Sentence with a unique object N2, taking the form of a direct sentential             |
| 110 1112 = 110 1 Qui Subj | complement in the subjunctive mood with as subject the object N1 of                  |
|                           | the basic construction   |
| (binary)                  | Example: Paul soupçonne Ida de boire = Paul soupçonne qu'Ida boit;                   |
| (billary)                 | Paul excuse Luc d'avoir fait $\varphi a = Paul$ excuse que Luc ait fait $\varphi a$  |
| N0 V N2 destination       | A locative object N2 interpreted as a destination can become the unique              |
|                           | object and a direct object, by erasement of other objects and of the                 |
|                           | preposition introducing N2   |
| (binary)                  | Example : Luc a bâti des immeubles sur toute la colline = Luc a bâti                 |
|                           | toute la colline; Luc crayonne des dessins sur sa feuille = Luc crayonne             |
|                           | sa feuille; La colonne piétine des pieds dans la boue = La colonne piétine           |
|                           | la boue  |
| N0 V N2 matériau          | An object N2 denoting material for the process can occur as a direct                 |
|                           | object by erasement of its preposition and of an object N1                           |
| (binary)                  | Example: Paul tricote un pull dans de la laine bleue = Paul tricote de               |
|                           | la laine bleue   |
| N0 V N2 source de N1      | A locative object N2 interpreted as a source can become a direct ob-                 |
|                           | ject, by erasement of its preposition, and coexist with an object de N1              |
|                           | (argument transposition)   |
| (binary)                  | Example: On a drainé toute cette eau de notre champ dans une fosse =                 |
|                           | On a drainé notre champ de toute cette eau   |
| N0 V Nhum sur ce point    | Sentence with a direct object N1 denoting a person, and an additional                |
|                           | complement of the form sur ce point  |
| (binary)                  | Example: Paul a consulté Luc sur cette question                                      |
| NO V N résultat           | An object interpreted as a result can appear as a unique object which                |
| Tro V II resultat         | is a direct object; it can also appear as an additional object with the              |
|                           | preposition en   |
| (binary)                  | Example: Paul tisse un tapis; Paul tisse les fils bleus et les fils rouges           |
| (Since y)                 | en un tapis  |
|                           | cie une cupos  |

Table E.21: Documentation des propriétés des tables de verbes (21)

| Feature              | Description of the feature  |
|----------------------|---|
| N0 V Prép N0pc       | A prepositional object Prép N1 can denote a body part of the person       |
|                      | denoted by the subject, or a part of the concrete object denoted by the   |
|                      | subject   |
| (binary)             | Example : Paul glisse sur le ventre ; La poutre repose sur le côté        |
| NO V Prép N1         | Sentence with a unique object Prép N1, possibly by erasement of other     |
| ·                    | objects; the preposition can be empty                                     |
| (binary)             | Example : Ceci servira à Paul (E+à écrire son article). Luc a retenu      |
|                      | Luc ( $E$ +de faire une bêtise)   |
| N0 V Prép N1 Prép N2 | Sentence with two objects Prép N1 and Prép N2, possibly by erasement      |
|                      | of other objects; the preposition introducing N1 can be empty             |
| (binary)             | Example : Ce bâton sert à Paul de matraque (E+pour se défendre)           |
| NO V Prép N1 Prép N2 | Sentence with three objects Prép N1, Prép N2 and Prép N3; the prepo-      |
| Prép N3              | sitions can be empty  |
| (binary)             | Example : Paul désigne Luc à Marie pour faire la corvée                   |
| NO V Prép N1 Prép N3 | Sentence with two objects Prép N1 and Prép N3, by erasement of other      |
|                      | objects; the prepositions can be empty                                    |
| (binary)             | Example : Paul désigne Luc (E+à Marie) pour faire la corvée               |
| N0 V Prép N1-hum     | Sentence with the same subject, the verb V, and a nominal object Prép     |
|                      | N1 with a non-human meaning   |
| (binary)             | Example: Paul commence par faire le tri des vis = Paul commence par       |
|                      | le tri des vis; Paul commence par faire le tri des vis = Paul commence    |
|                      | par les vis   |
| N0 V Prép N1hum      | Sentence with the same subject, the verb V, and a nominal object Prép     |
|                      | N1 denoting a person  |
| (binary)             | Example : Luc commence par répondre à Marie = Luc commence par            |
|                      | $Marie$ ; $Luc$ passe pour $\hat{e}tre$ un $as = Luc$ passe pour un $as$  |
| N0 V Prép N2         | Sentence with an object Prép N2, by erasement of other objects            |
| (binary)             | Example: Ce traitement immunise (E+les enfants) contre la grippe          |
| N0 V Prép N2 Prép N3 | Sentence with two objects Prép N2 and Prép N3, by erasement of other      |
|                      | objects; the preposition introducing N3 can be empty                      |
| (binary)             | Example : Paul pose (E+à Luc) comme condition que Léa parte               |
| N0 V Prép N3         | Sentence with an object Prép N3, by erasement of other objects            |
| (binary)             | Example : Ce parapluie sert (E+à Marie) (E+d'arme) pour se défendre       |
| N0 V Prép V0-inf W   | Insertion of the verb V into a sentence N0 V W, producing a sentence      |
|                      | with the same subject, the verb V, and an infinitive clause taking the    |
|                      | form Prép V0-inf W, with an implicit subject coreferent with N0; the      |
|                      | preposition can be empty  |
| (binary)             | Example: Paul prend une douche = Paul commence par prendre une            |
|                      | douche; Paul prend un bain = Paul ose prendre un bain                     |
| N0 V V0-inf W        | Sentence with a non-prepositional infinitive clause which has an implicit |
|                      | subject coreferent with that of the main verb; possibly by erasement of   |
|                      | other objects   |
| (binary)             | Example: Paul file acheter du pain; Paul traverse la rue acheter du pain  |
|                      | = Paul traverse acheter du pain   |
| N0 V vers N          | Additional complement of the form vers N, interpreted as a direction      |
|                      | to a destination; the sentence has no directional meaning without this    |
|                      | complement  |
| (binary)             | Example: Paul titube vers la sortie/ Paul titube (cf. L'avion pique vers  |
|                      | le sol/L'avion pique)   |

Table E.22: Documentation des propriétés des tables de verbes (22)

| Feature   | Description of the feature   |
|---|--|
| N0abs V N1hum   | Sentence with a subject denoting an abstract entity and an object N1   |
|   | denoting a person; the sentence has a metaphorical meaning   |
| (binary)  | Example : Les soucis bouffent Léa  |
| N0hum V Loc Nabs  | Sentence with a subject denoting a person and a locative complement  |
| Tronam v Zoe raze   | denoting an abstract entity; the sentence has a metaphorical meaning   |
| (binary)  | Example: Paul voyage dans des rêves impossibles  |
| N0hum V W sur ce point  | Sentence with a subject denoting a person, and an additional comple-   |
| Worldin V VV Sur Ce point   | ment of the form $sur\ ce\ point$  |
| (binary)  | Example: Paul à menti à Léa sur ce point; Paul s'emporte contre Luc  |
| (billary)   | sur cette question   |
| N0idée V Loc N1esprit   | Sentence with a subject denoting an idea and a locative complement   |
| Noidee V Loc Niespiit   | denoting a person's mind; the sentence has a metaphorical meaning  |
| (binary)  | Example: L'idée d'essayer frétillait dans son esprit   |
| N0pc lui V W  | Pronominalization of a noun which denotes a person and is a post-  |
| Nope idi v vv   | modifier of a subject denoting a body part; the pronoun is a dative  |
|   | clitic cl |
| (binary)  | Example : Les yeux lui clignent ; La tête lui a percuté contre le dossier  |
| $\begin{array}{c} \text{(Biliary)} \\ \text{N1} = \text{(N) (Adj)} \end{array}$ | A type of subject raising: a sentential complement N1 in the indica-   |
| 101 = (10) (Adj)  | tive mood taking the form que N être Adj W can be replaced with a  |
|   | constituent N followed by an objective complement Adj W  |
| (binary)  | Example: J'imagine que Marie est enceinte = J'imagine Marie  |
| (billary)   | enceinte   |
| N1 = (N) (être Adj)   | A type of subject raising: a sentential complement N1 in the indica-   |
| ivi = (iv) (etie Auj)   | tive mood taking the form que N être Adj W can be replaced with a  |
|   | constituent N followed by an infinitive clause être Adj W  |
| (binary)  | Example: J'imagine que Marie est ironique = J'imagine Marie être   |
| (Sincery)   | ironique   |
| N1 = (N) (V-ant W)  | A type of subject raising: a sentential complement N1 in the indicative  |
|   | mood taking the form que N V W can be replaced with a constituent N  |
|   | followed by a participial clause V-ant W   |
| (binary)  | Example : J'ai repéré que Paul travaille = J'ai repéré Paul tra-   |
|   | vaillant   |
| N1 = (N) (V-inf W)  | A type of subject raising: a sentential complement N1 in the indicative  |
|   | mood taking the form que N V W can be replaced with a constituent N  |
|   | followed by an infinitive clause V-inf W   |
| (binary)  | Example: Je vois que Paul travaille = Je vois Paul travailler  |
| N1 = où   | An object N1 answers a question in $où$ ?  |
| (binary)  | Example : Où le livre est-il paru? - Il est paru chez Plon; D'où l'eau   |
|   | filtre-t-elle? - Elle filtre du plafond  |
| N1 = Ppv  | A nominal object N1 can pronominalize into a clitic  |
| (binary)  | Example: $Paul\ aime\ Marie = Paul\ l'aime$  |
| N1 =: Qu P = Aux V0-inf   | A direct sentential complement in the indicative mood noted N1, when its   |
| W   | subject is coreferent to the main subject and it contains an auxiliary or  |
|   | some verbs (Gross, 1975) (p. 76), can be replaced by a non-prepositional   |
|   | infinitive clause with an implicit subject coreferent to the main subject  |
| (binary)  | Example: Paul dit qu'il a dormi = Paul dit avoir dormi; Paul dit qu'il   |
|   | ignore l'anglais = Paul dit ignorer l'anglais (cf. Paul dit qu'il se promène,  |
|   | *Paul dit se promener); Paul inscrit dans l'agenda qu'il a fait ça = Paul  |
|   | inscrit dans l'agenda avoir fait ça  |

Table E.23: Documentation des propriétés des tables de verbes (23)

| Feature                          | Description of the feature   |
|----------------------------------|--|
| N1 =: ce(ci+la)                  | A sentential complement N1 can pronominalize in the form of <i>ceci</i> or |
|                                  | cela   |
| (binary)                         | Example : Cet échec équivaut pour Max à ce qu'il doive changer d'objectif  |
| (**, )                           | = Cet échec équivaut pour Max à (ceci+cela)                                |
| N1 =: combien P                  | An object N1 can take the form of an exclamative clause                    |
| (binary)                         | Example: Max contemple combien tout est beau                               |
| N1 =: coup                       | An object N1 can denote a blow   |
| (binary)                         | Example : Max allonge une claque à Léa; Paul reçoit un coup de pied        |
|                                  | de Jean  |
| N1 =: de V0-inf W                | A direct object N1 can take the form of an infinitive clause introduced    |
|                                  | by the preposition de, with an implicit subject coreferent to the main     |
|                                  | subject  |
| (binary)                         | Example : Paul subordonne de faire ça au résultat des élections            |
| N1 =: de V2c-inf W               | A direct object N1 can take the form of an infinitive clause introduced    |
|                                  | by the preposition $de$ , with an implicit subject coreferent to a nominal |
|                                  | post-modifier of a nominal object N2                                       |
| (binary)                         | Example : Paul incorpore dans les instructions de Luc de faire la vais-    |
|                                  | selle  |
| N1 =: de V2-inf W                | A direct object N1 can take the form of an infinitive clause introduced    |
|                                  | by the preposition $de$ , with an implicit subject coreferent to an object |
|                                  | N2   |
| (binary)                         | Example : Ceci justifie pour Paul de démissionner                          |
| N1 =: Dnum Nmes                  | An object N1 can take the form of a cardinal numeral and a noun of         |
|                                  | measurement unit   |
| (binary)                         | Example : Ce vin titre 13 degrés   |
| N1 =: Dnum Nmonnaie              | An object N1 can take the form of a cardinal numeral and a noun of         |
|                                  | measurement unit, denote a sum of money and answer a question in           |
|                                  | combien?   |
| (binary)                         | Example : Paul a avancé 100 francs à Jean ; Combien Paul a-t-il avancé     |
|                                  | à Jean?  |
| N1 =: esprit, N2 =: idée         | An object N1 can denote a person's mind and an object N2 an idea; the      |
|                                  | sentence has a metaphorical meaning  |
| (binary)                         | Example : Paul embarrasse son esprit d'idées saugrenues ; Luc débarrasse   |
|                                  | sa tête de ces projets idiots  |
| $N1 =: id\acute{e}e, (N2+N3) =:$ | An object N1 can denote an idea, and an object noted N2 or N3, a           |
| esprit                           | person's mind; the sentence has a metaphorical meaning with regard to      |
|                                  | the locative meaning   |
| (binary)                         | Example : Léa a évacué ces idées de l'esprit de Luc                        |
| N1 =: idée, N2 =: esprit         | An object N1 can denote an idea and an object N2 a person's mind; the      |
|                                  | sentence has a metaphorical meaning  |
| (binary)                         | Example : Paul a fourré de drôles d'idées dans la tête de Luc              |
| N1 =: le fait Qu P               | An object N1 can take the form of le fait que P, close to a sentential     |
|                                  | complement, and denote an abstract entity                                  |
| (binary)                         | Example : Max a décortiqué le fait que Paul ne soit pas venu               |
| N1 =: mot, (N2+N3) =:            | An object N1 can denote words, and an object noted N2 or N3, a text;       |
| texte                            | the sentence has a metaphorical meaning with regard to the locative        |
|                                  | meaning  |
| (binary)                         | Example : Paul bannit les grossièretés de ses articles ; Paul a centralisé |
|                                  | les informations dans son article  |

Table E.24: Documentation des propriétés des tables de verbes (24)

| Feature                                 | Description of the feature  |
|---|---|
| N1 =: mot, N2 =: texte                  | An object N1 can denote words and an object N2 a text; the sentence           |
| ,                                       | has a metaphorical meaning  |
| (binary)                                | Example: Paul a introduit des citations bizarres dans son article; Paul       |
|   | saupoudre des plaisanteries dans ses discours                                 |
| N1 =: Nabs                              | An object N1 can denote an abstract entity                                    |
| (binary)                                | Example : Paul dispense des conseils ; Paul attribue de l'importance à ce     |
| (************************************** | que dit Léa   |
| N1 =: Nabs métaphore                    | An object N1 can denote an abstract entity; the sentence has a meta-          |
|   | phorical meaning (N1 normally denotes obligatorily a person or concrete       |
|   | object)   |
| (binary)                                | Example : Ces contraintes asphyxient mon enthousiasme ; Paul a abîmé          |
| (************************************** | son amour-propre  |
| N1 =: Nconc                             | An object N1 can denote a concrete object                                     |
| (binary)                                | Example : Le radar suit la fusée  |
| N1 =: Nconc métaphore                   | An object N1 can denote a concrete object; the sentence has a metapho-        |
|   | rical meaning (N1 normally denotes obligatorily a person)                     |
| (binary)                                | Example: Paul rapatrie ses capitaux en France                                 |
| N1 =: Nhum                              | An object N1 can denote a person  |
| (binary)                                | Example : Cette robe va très bien à Marie; On a vacciné Paul contre           |
|   | le tétanos; Léa confie son fils à des voisins; Ida rassasie son chat de       |
|   | poisson   |
| N1 =: N-hum                             | An object N1 can denote an entity which is not a person                       |
| (binary)                                | Example : Luc court après l'argent ; Max ampute sa thèse de deux              |
|   | chapitres   |
| N1 =: Npc                               | An object N1 can denote a body part   |
| (binary)                                | Example: Paul joint le pouce avec l'index                                     |
| N1 =: Npc obl                           | An object N1 denotes obligatorily a body part, or, metonymically, a           |
|   | person  |
| (binary)                                | Example : Le soleil a basané la peau de Max = Le soleil a basané Max          |
| N1 =: Npl obl                           | An object N1 is obligatorily in the plural or has a collective interpretation |
| (binary)                                | Example : La bouteille a éclaté en mille morceaux                             |
| N1 =: Qu P                              | An object N1 can take the form of a sentential complement, in a sentence      |
|   | with a metaphorical meaning   |
| (binary)                                | Example : On exhume de manuscrits grecs que la Terre est ronde                |
| N1 =: Qu P = Ppv                        | An object N1 taking the form of a sentential complement can pronomi-          |
|   | nalize into a clitic  |
| (binary)                                | Example : Paul a combiné avec Luc que Marie soit écartée = Paul               |
|   | l'a combiné avec Luc; Luc va empêcher que Marie vienne = Luc va               |
|   | l'empêcher  |
| N1 =: Qu Pind                           | An object N1 can take the form of a sentential complement in the in-          |
|   | dicative mood. When N1 is introduced by a preposition, the particle ce        |
|   | appears between the preposition and the complementizer que                    |
| (binary)                                | Example: Paul instaure que les réunions auront lieu à 10 h; Ceci découle      |
| N1 O D I                                | de ce que Luc est revenu  |
| N1 =: Qu Psubj                          | An object N1 can take the form of a sentential complement in the sub-         |
|   | junctive mood. When N1 is introduced by a preposition, the particle <i>ce</i> |
| (1. :)                                  | appears between the preposition and the complementizer que                    |
| (binary)                                | Example: Paul instaure que les réunions aient lieu à 10 h; Luc a              |
|   | contribué à ce que Paul soit élu  |

Table E.25: Documentation des propriétés des tables de verbes (25)

Table E.26: Documentation des propriétés des tables de verbes (26)

| Feature                          | Description of the feature  |
|----------------------------------|---|
| N1 être V-ant                    | An object $N1$ can become the subject of a sentence with $\hat{e}tre$ followed by a deverbal adjective morphologically associated with $V$ , with the suffix $-ant$ ; other objects are not preserved                                 |
| (binary)                         | Example: Le papier est jaunissant; Le gibier est abondant   |
| N1 être V-ant Prép N0            | An object N1 can become the subject of a sentence with $\hat{e}tre$ followed by a deverbal adjective morphologically associated with V, with the suffix -ant, and by an object Prép N0  |
| (binary)                         | Example : Les étoiles sont étincelantes dans le ciel = Le ciel étincelle d'étoiles = Le ciel est étincelant d'étoiles   |
| N1 être V-n (binary)             | An object N1 can become the subject of a sentence with être and a deverbal noun morphologically associated with V as a 'predicate nominative' Example: Paul a torchonné son article = Son article est un torchon                      |
| N1 être V-n (forme V-n)          | Form of a deverbal noun morphologically associated with V, used when an object N1 becomes the subject of a sentence with $\hat{e}tre$ followed by the deverbal noun as a 'predicate nominative'                                       |
| (lexical)                        | Example: torchon  |
| N1 être V-n pour N0              | An object N1 can become the subject of a sentence with <i>être</i> followed by a deverbal noun morphologically associated with V, and by an object pour N0  |
| (binary)                         | Example: $Paul\ abomine\ cette\ situation = Cette\ situation\ est\ une\ abomination\ pour\ Paul$  |
| N1 être V-n pour N0 (forme V-n)  | Form of a deverbal noun morphologically associated with V, used when an object N1 becomes the subject of a sentence with $\hat{e}tre$ followed by the deverbal noun and by an object pour N0  |
| (lexical)                        | Example: abomination  |
| N1 être V-n, Sfx # E             | An object N1 can become the subject of a sentence with <i>être</i> followed by a deverbal noun morphologically associated with V, with a non-empty suffix   |
| (binary)                         | Example: Le volcan projette de la cendre = La cendre est une projection;<br>Luc bave sur la serviette = Luc fait une bavure sur la serviette  |
| N1 être V-n, Sfx # E (forme V-n) | Form of a deverbal noun morphologically associated with V, used when an object N1 becomes the subject of a sentence with $\hat{e}tre$ followed by the deverbal noun, with a non-empty suffix  |
| (lexical)                        | Example: bavure   |
| N1 être Vpp                      | Passive without complements, acceptable in the present tense and interpreted as a static result   |
| (binary)                         | Example : Luc balaie le couloir de tous les détritus = Le couloir est balayé; Luc ancre le bateau dans la crique = Le bateau est ancré; Le choc éboule le mur en gravats = Le mur est éboulé  |
| N1 être Vpp de ce Qu P           | Passivization of a sentence with a sentential subject; the agent is introduced by the preposition $de$ ; other objects, if any, are not preserved; the sentence is acceptable in the present tense and interpreted as a static result |
| (binary)                         | Example : Que Luc s'en aille étonne Paul = Paul est étonné de ce que Luc s'en aille ; Que Marie soit venue excite Pierre à se faire valoir = Pierre est excité de ce que Marie soit venue   |

Table E.27: Documentation des propriétés des tables de verbes (27)

| Feature                    | Description of the feature   |
|----------------------------|--|
| N1 être Vpp de N0          | Passivization with agent introduced by the preposition $de$ ; other objects, |
| P.P                        | if any, are not preserved; if N1 is a prepositional object, it becomes the   |
|                            | passive subject without its preposition                                      |
| (binary)                   | Example: Tous détestent Paul = Paul est détesté de tous; Tous ont            |
| (Silicity)                 | discuté de ce problème = Ce problème a été discuté de tous                   |
| N1 être Vpp de N0 à ce Qu  | Passivization with agent introduced by the preposition $de$ ; an object à    |
| P                          | ce Qu P is preserved   |
| (binary)                   | Example : Paul a été encouragé de tous à faire ça                            |
| N1 être Vpp de N0 de ce    | Passivization with agent introduced by the preposition $de$ ; an object de   |
| Qu P                       | ce Qu P is preserved   |
| (binary)                   | Example : Paul a été hué de la foule d'avoir fait ça                         |
| N1 être Vpp de N0 Prép N2  | Passivization with agent introduced by the preposition de; an object         |
|                            | Prép N2 is preserved; if N1 is a prepositional object, it becomes the        |
|                            | passive subject without its preposition                                      |
| (binary)                   | Example: Tous ont lu la nouvelle dans le journal = La nouvelle a été lue     |
| (biiiaiy)                  | de tous dans le journal; Tous ont attesté de ce fait auprès des enquêteurs   |
|                            | = Ce fait a été attesté de tous auprès des enquêteurs                        |
| N1 être Vpp par N0         | Passivization with agent introduced by the preposition par; other objects    |
| NI etre vpp par NO         |  |
|                            | are not preserved; if N1 is a prepositional object, it becomes the passive   |
| (himany)                   | subject without its preposition  |
| (binary)                   | Example: Tous détestent Paul = Paul est détesté par tous; Tous ont           |
| NII û                      | discuté de ce problème = Ce problème a été discuté par tous                  |
| N1 être Vpp par N0 à ce Qu | Passivization with agent introduced by the preposition $par$ ; an object à   |
| P (1:                      | ce Qu P is preserved   |
| (binary)                   | Example : Paul a été encouragé par tous à faire ça                           |
| N1 être Vpp par N0 de ce   | Passivization with agent introduced by the preposition par; an object        |
| Qu P                       | de ce Qu P is preserved  |
| (binary)                   | Example : Paul a été hué par la foule d'avoir fait ça                        |
| N1 être Vpp par N0 Prép    | Passivization with agent introduced by the preposition par; an object        |
| N2                         | Prép N2 is preserved; if N1 is a prepositional object, it becomes the        |
| (1.                        | passive subject without its preposition                                      |
| (binary)                   | Example: Tous ont lu la nouvelle dans le journal = La nouvelle a été lue     |
|                            | par tous dans le journal; Tous ont attesté de ce fait auprès des enquêteurs  |
|                            | = Ce fait a été attesté par tous auprès des enquêteurs                       |
| N1 être Vpp W              | Passivization without agent; prepositional objects, if any, are preserved;   |
|                            | the sentence is acceptable in the present tense and interpreted as a static  |
|                            | result   |
| (binary)                   | Example : Le mot chien est traduit par le mot dog; Ce pain est grillé        |
|                            | (cf. *Cet oeuf est gobé)   |
| N1 lieu de destination de  | An object N1 is interpreted as a destination of the referent of N0. The      |
| N0                         | criterion to be applied is that of support sentences as in Boons et al.      |
|                            | (1976b) (p. 205) and in Guillet et Leclère (1992) (p. 22)                    |
| (binary)                   | Example: Max atteint le sommet   |
| N1 lieu de destination de  | An object N1 is interpreted as a destination of the referent of N2. The      |
| N2                         | criterion to be applied is that of support sentences as in Boons et al.      |
|                            | (1976b) (p. 205) and in Guillet et Leclère (1992) (p. 22)                    |
| (binary)                   | Example : Luc sale le rôti de sel fin  |

Table E.28: Documentation des propriétés des tables de verbes (28)

| Feature                  | Description of the feature   |
|--------------------------|--|
| N1 lieu de passage de N0 | An object N1 is interpreted as a place where the referent of the subject         |
|                          | passes; the sentence is interpreted with a punctual aspect                       |
| (binary)                 | Example: Le car emprunte l'avenue  |
| N1 lieu source de N0     | An object N1 is interpreted as the source of the referent of N0. The             |
|                          | criterion to be applied is that of support sentences as in Boons et al.          |
|                          | (1976b) (p. 205) and in Guillet et Leclère (1992) (p. 22)                        |
| (binary)                 | Example: L'ennemi abandonne la ville   |
| N1 lieu source de N2     | An object N1 is interpreted as the source of the referent of N2. The             |
|                          | criterion to be applied is that of support sentences as in Boons et al.          |
|                          | (1976b) (p. 205) and in Guillet et Leclère (1992) (p. 22)                        |
| (binary)                 | Example: Max cure le puits de sa vase  |
| N1 lieu statique de N0   | An object N1 is interpreted as a place where the referent of the subject is      |
| ·                        | before, during and after the process. The criterion to be applied is that        |
|                          | of support sentences as in Boons <i>et al.</i> (1976b) (p. 205) and in Guillet   |
|                          | et Leclère (1992) (p. 22)  |
| (binary)                 | Example : Léa arpente le boulevard   |
| N1 se V (neutre)         | An object N1 can become the subject of a sentence with a pronominal              |
|                          | verb and no other objects; the reflexive clitic is in the accusative; the        |
|                          | sentence is not the result of the clitic pronominalization of an object N1       |
|                          | coreferent to NO; the sentence does not imply the existence of a human           |
|                          | agent; the sentence denotes a datable event (neutral construction in the         |
|                          | sense of Ruwet (1972))   |
| (binary)                 | Example: Le choc a ankylosé son bras = Son bras s'ankylose (as opposed           |
|                          | to: On entretient cette voiture facilement = Cette voiture s'entretient          |
|                          | facilement)  |
| N1 se V auprès de N3hum  | An object N1 denoting a person can become the subject of a sentence              |
| de ce Qu P               | with a pronominal verb, an object of the form de ce que P, which is either       |
|                          | NO or N2, and an additional object of the form auprès de N3, denoting            |
|                          | a person; the sentence implies a verbal communication between the two            |
|                          | persons; the reflexive clitic is in the accusative                               |
| (binary)                 | Example : Que Léa ne soit pas venue attriste Paul = Paul s'attriste              |
|                          | auprès de Marie de ce que Léa ne soit pas venue; Quelque chose                   |
|                          | réconforte Paul de ce qu'il a dû faire cela = Paul se réconforte auprès          |
|                          | de Marie de ce qu'il a dû faire cela   |
| N1 se V de ce Qu P       | An object N1 can become the subject of a sentence with a pronominal              |
|                          | verb and object of the form de ce que P, which is either N0 or N2; the           |
|                          | sentence may imply that N1 denotes a person which communicates ver-              |
|                          | bally with another person, or not; the reflexive clitic is in the accusative;    |
|                          | the sentence is not the result of the clitic pronominalization of an object      |
|                          | N1 coreferent to N0  |
| (binary)                 | Example: Que Max dorme choque Marie = Marie se choque de ce que                  |
|                          | $Max\ dort$ ; Que Marie dorme exacerbe l'ire de $Max = L$ 'ire de $Max\ s$ 'exa- |
|                          | cerbe de ce que Marie dort; Quelque chose console Luc de ce qu'il n'a            |
|                          | pas été élu = Luc se console de ce qu'il n'a pas été élu                         |

Table E.29: Documentation des propriétés des tables de verbes (29)

| Feature                  | Description of the feature  |
|--------------------------|---|
| N1 se V en N2 (statique) | An object N1 can become the subject of a sentence with a pronominal   |
| , , ,                    | verb and an object of the form en N2; the reflexive clitic is in the accu-  |
|                          | sative; the sentence is not the result of the clitic pronominalization of   |
|                          | an object N1 coreferent to N0; the sentence does not imply the existence  |
|                          | of a human agent; the sentence denotes a stative situation  |
| (binary)                 | Example: On divise le terrain en trois zones = Le terrain se divise en  |
| (Siliary)                | trois zones (as opposed to : Le choc casse le caillou en trois morceaux =   |
|                          | Le caillou se casse en trois morceaux)  |
| N1 V                     | An object N1 can become the subject of a sentence with no other objects   |
| I .                      | Example: $Paul\ chauffe\ la\ soupe=La\ soupe\ chauffe\ ;\ Luc\ gonfle\ le\ ballon$  |
| (binary)                 |   |
| NII V                    | $d'air = Le \ ballon \ gonfle \ (E + *d'air)$   |
| N1 V avec N2             | An object N1 can become the subject of a sentence with an object avec   |
|                          | N2  |
| (binary)                 | Example : Le juge a divorcé Ida d'avec Luc = Ida a divorcé avec Luc   |
| N1 V de ce Qu Pind       | An object N1 can become the subject of a sentence while the subject,  |
|                          | which takes the form of a sentential subject, becomes an object of the  |
|                          | form de ce que Pind, in the indicative mood   |
| (binary)                 | Example: Que Paul est vainqueur retentit dans toute la ville = Toute  |
|                          | la ville retentit de ce que Paul est vainqueur  |
| N1 V de N0 source        | An object N1 can become the subject of a sentence while the locative  |
|                          | subject, which is interpreted as a source, becomes an object introduced   |
|                          | by the preposition $de$   |
| (binary)                 | Example : La lampe irradie une lumière douce = Une lumière douce  |
|                          | irradie de la lampe   |
| N1 V de N1pc             | When a locative object, denoting a body part of a person, takes the form  |
|                          | Loc N1pc de N1, where N1 denotes the person, a sentence can have N1   |
|                          | as its subject and de N1pc as an object   |
| (binary)                 | Example: Des bruits incongrus glougloutent dans l'intestin de Jean =  |
|                          | Jean glougloute de l'intestin   |
| N1 V Loc N2              | An object N1 can become the subject of a sentence with an object Loc  |
|                          | N2; the sentence is interpreted either as processive or as a static result  |
| (binary)                 | Example: Max approche la bouteille du verre = La bouteille approche du  |
|                          | verre; Max tient le carton contre la caisse = Le carton tient contre la   |
|                          | caisse  |
| N1 V N2                  | An object N1 can become the subject of a sentence with a direct object  |
|                          | N2; the sentence is interpreted as processive   |
| (binary)                 | Example: Je cogne mon verre contre le tien = Mon verre cogne le tien  |
| N1 V Prép N0             | A locative object N1, with a scenic interpretation, can become the sub-   |
|                          | ject of a sentence, while the subject becomes an object introduced by a   |
|                          | preposition; some changes in determiners may take place   |
| (binary)                 | Example: Les abeilles grouillent dans le jardin = Le jardin grouille  |
| (Sinary)                 | Example . Les aventes grountent dans le jardin $=$ Le jardin grounte d'abeilles ; Les pins abondent dans la forêt $=$ La forêt abonde en pins |
| N1 V Prép N0 = N0 être   | Sentence with noun-centered argument structure, with the same subject,  |
| V-n                      | the verb être, and a deverbal noun related with V; the distribution of  |
| v -11                    |   |
| (binowy)                 | No in the sentence is a subset of its distribution in N1 V Prép No  |
| (binary)                 | Example: Le salon froufroute du bruit des soieries = Le bruit des soieries  |
|                          | est un froufrou (cf. Les soieries froufroutent dans le salon = Le salon   |
|                          | froufroute de soieries, *Les soieries sont un froufrou)   |

Table E.30: Documentation des propriétés des tables de verbes (30)

| Feature            | Description of the feature   |
|--------------------|--|
| N1 V Prép N0hum    | In N1 V Prép N0, the object N0 may denote persons                          |
| (binary)           | Example : La rue déborde de touristes (cf. *Les touristes débordent dans   |
|                    | la rue)  |
| N1 V Prép N0pl obl | In N1 V Prép N0, the object N0 is obligatorily in the plural or has a      |
|                    | collective interpretation  |
| (binary)           | Example: Des rires moqueurs fusèrent dans la salle = La salle fusa de      |
|                    | rires moqueurs (cf. Un rire moqueur fusa dans la salle, *La salle fusa     |
|                    | d'un rire moqueur)   |
| N1 V W             | An object N1 can become the subject of a sentence with conservation of     |
|                    | its other objects, if any  |
| (binary)           | Example: Max enfonce le bâton dans le sable = Le bâton enfonce dans        |
|                    | le sable   |
| N1c =: Nhum        | A nominal direct object of the form N1 de N1c, where N1c denotes a         |
|                    | person, can be replaced by N1c and a prepositional modifier Prép N1        |
|                    | called 'echo modifier' (restructuration)                                   |
| (binary)           | Example : Ceci confirme la décision de Luc = Ceci confirme Luc dans        |
|                    | sa décision  |
| N1c =: N-hum       | A nominal direct object of the form N1 de N1c, where N1c denotes a         |
|                    | non-human entity, can be replaced by N1c and a prepositional modifier      |
|                    | Prép N1 called 'echo modifier' (restructuration)                           |
| (binary)           | Example : Ceci freine l'élan de l'avalanche = Ceci freine l'avalanche      |
|                    | dans son élan  |
| N1c être Vpp       | A post-modifier of a direct object N1 can become the subject of a sen-     |
|                    | tence with être and the past participle of V; the sentence has a stative   |
|                    | interpretation   |
| (binary)           | Example : Ceci a ébranlé les certitudes de Luc = Luc est ébranlé           |
| N1-hum = Ppv       | An object N1 denoting a non-human entity can be pronominalized into        |
|                    | a clitic pronoun   |
| (binary)           | Example: Luc suspend sa décision à une condition = Luc la suspend à        |
|                    | $une \ condition$  |
| N1hum V Prép N0    | In N1 V Prép N0, the subject N1, with a scenic interpretation, may denote  |
|                    | a person   |
| (binary)           | Example: Marie rutile de diamants  |
| N1pc lui V         | When an object, denoting a body part of a person, takes the form N1pc      |
|                    | de N1, where N1 denotes the person, a sentence can have N1pc as its        |
|                    | subject and a dative clitic coreferent to N1                               |
| (binary)           | Example : Le froid hérisse les poils de Luc = Les poils lui hérissent ; De |
|                    | $la\ sueur\ suinte\ sur\ le\ front\ de\ Luc\ =\ Le\ front\ lui\ suinte$    |
| N2 =: Adj          | An object N2 can take the form of an adjective along with its objects and  |
|                    | modifiers, if any  |
| (binary)           | Example : Paul proclame Luc digne de ce titre                              |
| N2 =: ce(ci+la)    | A sentential complement N2 can pronominalize in the form of ceci or        |
|                    | cela   |
| (binary)           | Example : Paul habitue Luc à ce qu'il n'y ait pas de déjeuner = Paul       |
|                    | habitue Luc à cela   |
| N2 =: couche       | An object N2 can be interpreted as a layer of a concrete substance         |
| (binary)           | Example: Luc badigeonne le mur (E+d'une couche) de chaux; Luc en-          |
|                    | colle le papier (E+d'une pellicule) de colle                               |
|                    | - · · · · · · · · · · · · · · · · · · ·                                    |

Table E.31: Documentation des propriétés des tables de verbes (31)

| Feature            | Description of the feature   |
|--------------------|--|
| N2 =: coup         | An object N2 can be interpreted as a blow                                      |
| (binary)           | Example : Luc martèle la table de coups de poing ; Luc scande son chant        |
|                    | de claquements de mains  |
| N2 =: déformation  | An object N2 can denote the type of distorsion underwent by the object         |
|                    | N1   |
| (binary)           | Example : Paul a cabossé le plateau de grosses bosses                          |
| N2 =: Dnum Nmes    | A direct complement N2 can take the form of a cardinal numeral followed        |
|                    | by a noun of measurement unit  |
| (binary)           | Example: Paul cote ce livre 100 euros  |
| N2 =: le fait Qu P | An object N2 can take the form le fait que P, close to a sentential com-       |
|                    | plement, and denote an abstract entity   |
| (binary)           | Example : Paul avertit Luc du fait que Léa arrive                              |
| N2 =: N de V-n     | The object N2 is of the form N de V-n, where V-n is a deverbal noun            |
|                    | related to V   |
| (binary)           | Example : On a empierré la route de (E+une couche de) pierres                  |
| N2 =: Nhum         | An object N2 can denote a person   |
| (binary)           | Example : Luc éloigne Paul de Marie ; On évacue la salle de tous les           |
|                    | gêneurs; Le général assiège la ville de troupes fraîches                       |
| N2 =: N-hum        | An object N2 can denote an entity which is not a person                        |
| (binary)           | Example : On a débarrassé la cave de toutes les bouteilles ; On a attribué     |
|                    | le prix à cette oeuvre   |
| N2 =: Npc          | An object N2 can denote a body part  |
| (binary)           | Example: Paul joint le pouce avec l'index                                      |
| N2 =: Npl obl      | An object N2 is obligatorily in the plural or has a collective interpretation  |
| (binary)           | Example : Luc distribue des bonbons (*à l'+aux) enfants ; Luc émaille          |
|                    | son récit (?*d'une+de) citations   |
| N2 =: Npr          | An object N2 can take the form of a proper name                                |
| (binary)           | Example : Paul a baptisé sa fille Marie  |
| N2 =: point        | An object N2 can have as its head noun the noun point interpreted as           |
|                    | an abstract entity   |
| (binary)           | Example: Paul subdivise son chapitre en plusieurs points                       |
| N2 =: Qu Pind      | A prepositional object N2 can take the form of a sentential complement         |
|                    | in the indicative mood. The particle <i>ce</i> appears between the preposition |
|                    | and the complementizer que   |
| (binary)           | Example : Max hue le gardien de ce qu'il a raté la balle                       |
| N2 =: Qu Psubj     | A prepositional object N2 can take the form of a sentential complement in      |
|                    | the subjunctive mood. The particle <i>ce</i> appears between the preposition   |
|                    | and the complementizer que, except if the object is introduced by pour,        |
|                    | avec or et   |
| (binary)           | Example : Ceci incite Zoé à ce que tout soit en ordre ; Max compte sur         |
|                    | Luc pour que tout soit en ordre; Luc alterne que le fil rouge passe sur le     |
|                    | bleu et qu'il passe dessous  |
| N2 =: si P ou si P | An object N2 can take the form of an interrogative clause                      |
| (binary)           | Example : Paul avisera Luc si Léa vient ou pas                                 |
| N2 =: trace        | An object N2 can denote marks  |
| (binary)           | Example : Paul a paginé ses feuilles de numéros fantaisistes                   |
| N2 =: trou         | An object N2 can denote a hole   |
| (binary)           | Example : Luc composte le ticket d'un petit trou carré ; Luc entaille le       |
|                    | bâton d'une entaille profonde  |

Table E.32: Documentation des propriétés des tables de verbes (32)

| Feature                 | Description of the feature  |
|-------------------------|---|
| N2 =: V-n de N          | The object N2 is of the form V-n de N, where V-n is a deverbal noun       |
|                         | related to V  |
| (binary)                | Example : Paul assaisonne son plat de (E+un assaisonnement de) épices     |
| ( , ,                   | exotiques   |
| N2 =: V0-inf W          | An object N2 can take the form of an infinitive clause, with an implicit  |
|                         | subject coreferent to the main subject                                    |
| (binary)                | Example : Paul menace Léa de la quitter                                   |
| N2 =: V1c-inf W         | An object N2 can be an infinitive clause with an implicit subject core-   |
|                         | ferent with a nominal post-modifier of a nominal object N1                |
| (binary)                | Example : La situation limite l'activité de Paul à amuser Marie           |
| N2 =: V1-inf W          | An object N2 can take the form of an infinitive clause, with an implicit  |
|                         | subject coreferent to an object N1  |
| (binary)                | Example: Ceci a réduit Luc à mendier                                      |
| N2 =: zone              | An object N2 can denote a zone  |
| (binary)                | Example : Paul a morcelé son terrain en plusieurs zones                   |
| N2 apparition           | An object N2 is interpreted as appearing or being created during the      |
| 142 appartion           | process   |
| (binary)                | Example : Le soleil a basané sa peau d'un hâle cuivré; On a bruité ce     |
| (binary)                | court métrage de bruits désagréables                                      |
| N2 bénéficiaire         | An object N2 is interpreted as receiving the referent of N1 as a benefit  |
| (binary)                | Example: On a accordé un prêt à Luc                                       |
| N2 destination V N1     | An object N2, interpreted as a destination, can become the subject of a   |
| N2 destination v N1     | sentence with a direct object N1; the sentence is interpreted as a static |
|                         | result  |
| (himany)                |   |
| (binary)                | Example: Paul rassemble les informations dans un fichier = Un fichier     |
| NO détaire entries      | rassemble les informations  |
| N2 détrimentaire        | An object N2 is interpreted as losing the referent of N1                  |
| (binary)                | Example : Luc hérite une horloge de sa grand-mère ; Luc a acheté cet      |
| NO St. W.               | immeuble à Marie  |
| N2 être V-n             | Sentence with noun-centered argument structure, with an object N2 as      |
| (1:                     | the subject, the verb <i>être</i> , and a deverbal noun related with V    |
| (binary)                | Example: On a monétisé ce métal en pièces = Les pièces sont de la         |
|                         | monnaie; Max a affermé sa terre à Luc = Luc est fermier; On a démoulé     |
| NO Star Market          | le gâteau de cet ustensile = Cet ustensile est un moule                   |
| N2 être V-n (forme V-n) | Form of a deverbal noun morphologically associated with V, used in a      |
|                         | sentence with noun-centered argument structure, with an object N2 as      |
| (1 • 1)                 | the subject, the verb <i>être</i> , and the deverbal noun related         |
| (lexical)               | Example: monnaie  |
| N2 être V-n, Sfx # E    | Sentence with noun-centered argument structure, with an object N2 as      |
|                         | the subject, the verb être, and a deverbal noun related with V with a     |
| (1.                     | non-empty suffix  |
| (binary)                | Example: Luc accoutre Léa d'une tenue invraisemblable = Cette tenue       |
|                         | est un accoutrement; On inonde la région d'une eau boueuse = Cette        |
|                         | eau boueuse est une inondation; On pèle les fruits de leur peau = Leur    |
|                         | peau est une pelure   |

TABLE E.33: Documentation des propriétés des tables de verbes (33)

| Feature                   | Description of the feature  |
|---------------------------|---|
| N2 être V-n, $Sfx = E$    | Sentence with noun-centered argument structure, with an object N2 as  |
| ,                         | the subject, the verb $\hat{e}tre$ , and a deverbal noun related with V with an   |
|                           | empty suffix  |
| (binary)                  | Example : Luc débroussaille l'allée de ces ronces = Ces ronces sont des   |
|                           | broussailles; On a asphalté la route de ce revêtement = Ce revêtement   |
|                           | est de l'asphalte   |
| N2 lieu de destination de | An object N2 is interpreted as the destination of the referent of the   |
| N0                        | subject. The criterion to be applied is that of support sentences as in   |
|                           | Boons <i>et al.</i> (1976b) (p. 205) and in Guillet et Leclère (1992) (p. 22)   |
| (binary)                  | Example : Le bus débouche de la rue sur la place  |
| N2 lieu de destination de | An object N2 is interpreted as the destination of the referent of N1. The   |
| N1                        | criterion to be applied is that of support sentences as in Boons <i>et al.</i>  |
|                           | (1976b) (p. 205) and in Guillet et Leclère (1992) (p. 22)   |
| (binary)                  | Example: Paul souffle de l'air dans le ballon   |
| N2 lieu source de N1      | An object N2 is interpreted as the source of the referent of N1. The  |
| 1.12 fied Source de IVI   | criterion to be applied is that of support sentences as in Boons et al.   |
|                           | (1976b) (p. 205) and in Guillet et Leclère (1992) (p. 22)   |
| (binary)                  | Example: La grue a levé le bloc du sol  |
| N2 lieu statique de N1    | An object N2 is interpreted as a place where the referent of an object  |
| 142 neu statique de 141   | N1 is before, during and after the process. The criterion to be applied   |
|                           | is that of support sentences as in Boons <i>et al.</i> (1976b) (p. 205) and in  |
|                           | Guillet et Leclère (1992) (p. 22)   |
| (binary)                  | Example: Bob cuit la porcelaine au four   |
| N2 scénique être V-n      | A locative modifier N2, with a scenic interpretation, can become the  |
| 142 Scenique etre V II    | subject of a sentence with être and a deverbal noun related with V as a   |
|                           | 'predicate nominative'  |
| (binary)                  | Example: Paul forge des objets dans cet atelier = Cet atelier est une   |
| (*                        | forge   |
| N2 scénique être V-n      | Form of a deverbal noun morphologically associated with V, used when  |
| (forme V-n)               | a locative modifier N2, with a scenic interpretation, becomes the subject   |
| (                         | of a sentence with être and the deverbal noun as a 'predicate nominative'   |
| (lexical)                 | Example: forge  |
| N2 V N1                   | An object N2 can become the subject of a sentence with a direct object  |
|                           | N1; the sentence is interpreted as a static result  |
| (binary)                  | Example: Luc assaisonne la salade de mayonnaise = De la mayonnaise  |
|                           | assaisonne la salade ; Luc dissimule le sac derrière le rideau = Le rideau  |
|                           | dissimule le sac; On a représenté la chapelle par une croix = Une croix   |
|                           | représente la chapelle  |
| N3 =: ce(ci+la)           | A sentential complement N3 can pronominalize in the form of <i>ceci</i> or  |
| ( ,)                      | cela  |
| (binary)                  | Example : Paul paye une grosse somme à Luc pour que la lettre arrive  |
|                           | $\grave{a} \ temps = Paul \ paye \ une \ grosse \ somme \ \grave{a} \ Luc \ pour \ cela$  |
| N3 =: de V1-inf W         | An object N3 can take the form of an infinitive clause introduced by the  |
|                           | preposition de, with an implicit subject coreferent to an object N1   |
| (binary)                  | Example: Paul donne à Luc comme travail de faire ça   |
| N3 =: le fait Qu P        | An object N3 can take the form le fait que P, close to a sentential com-  |
|                           | plement, and denote an abstract entity  |
| (binary)                  | Example : On défend le métal de la corrosion par le fait que les embruns  |
| (                         | ne peuvent plus l'atteindre   |
|                           | 100 power of process of the process |

Table E.34: Documentation des propriétés des tables de verbes (34)

| Feature                   | Description of the feature  |
|---------------------------|---|
| N3 =: Nhum                | An object N3 can denote a person  |
| (binary)                  | Example: Max défend la ville de bastions contre l'ennemi                      |
| N3 =: N-hum               | An object N3 can denote an entity which is not a person                       |
| (binary)                  | Example: Paul désigne Luc à Léa pour cette corvée                             |
| N3 =: Npl obl             | An object N3 is obligatorily in the plural or has a collective interpretation |
| (binary)                  | Example: Paul répartit les élèves dans quatre classes                         |
| N3 =: Qu Pind             | An object N3 can take the form of a sentential complement in the indi-        |
| NS —. Qu Filid            | cative mood   |
| (hinamı)                  |   |
| (binary)                  | Example: Paul mise cet argent sur Luc qu'il va gagner la course               |
| N3 =: Qu Psubj            | An object N3 can take the form of a sentential complement in the sub-         |
| (1:                       | junctive mood   |
| (binary)                  | Example: Paul sert à Luc de complice pour qu'il fasse ça                      |
| N3 =: V0-inf W            | An object N3 can take the form of an infinitive clause, with an implicit      |
|                           | subject coreferent to the main subject  |
| (binary)                  | Example: J'obtiens une aide de Luc pour me soigner                            |
| N3 =: V1-inf W            | An object N3 can take the form of an infinitive clause, with an implicit      |
|                           | subject coreferent to an object N1  |
| (binary)                  | Example : Ces querelles servent de prétexte à Luc pour sortir                 |
| N3 =: V2-inf W            | An object N3 can take the form of an infinitive clause, with an implicit      |
|                           | subject coreferent to an object N2  |
| (binary)                  | Example : Paul donne du temps à Luc pour faire ça                             |
| N3 être V-n               | Sentence with noun-centered argument structure, with an object $N3$ as        |
|                           | the subject, the verb $\hat{e}tre$ , and a deverbal noun related with V       |
| (binary)                  | Example : Paul a classé les verbes dans ces dix groupes = Ces dix groupes     |
|                           | sont des classes  |
| N3 être V-n (forme V-n)   | Form of a deverbal noun morphologically associated with V, used in a          |
|                           | nominal sentence with an object N2 as the subject, the verb être, and         |
|                           | the deverbal noun related   |
| (lexical)                 | Example: classe   |
| N3 attache V N1           | A complement N3 attache denoting a tying system and interpreted as            |
|                           | an instrument can become the subject of a sentence with a direct object       |
|                           | N1; the sentence is interpreted as a static result                            |
| (binary)                  | Example : Luc ligature les lèvres de la plaie d'un fil rouge = Un fil rouge   |
|                           | ligature les lèvres de la plaie   |
| N3 lieu de destination de | An object N3 is interpreted as the destination of the referent of N1. The     |
| N1                        | criterion to be applied is that of support sentences as in Boons et al.       |
|                           | (1976b) (p. 205) and in Guillet et Leclère (1992) (p. 22)                     |
| (binary)                  | Example: Luc tracte la voiture de Gap à Dax                                   |
| N actif V N0              | The subject of the basic construction can be a direct object in a sentence    |
|                           | with a subject denoting a person which is interpreted as active               |
| (binary)                  | Example : (La table mesure 3 mètres) Paul mesure la table                     |
| Neg                       | A negative adverb is obligatorily present                                     |
| (binary)                  | Example : Luc n'arrête pas d'être dérangé                                     |
| où N0 V-il?               | In a sentence with a non-prepositional infinitive clause which has an im-     |
|                           | plicit subject coreferent with that of the main verb, the infinitive clause   |
|                           | answers a question with $o\hat{u}$ and no other object                        |
| (binary)                  | Example: Où Paul court-il? - Il court chercher du vin                         |
| (billary)                 | Example. Ou I was courses: - Is court dictated an out                         |

Table E.35: Documentation des propriétés des tables de verbes (35)

| Feature         | Description of the feature   |
|-----------------|--|
| où N0 V-il N1?  | In a sentence with a non-prepositional infinitive clause which has an im-  |
|                 | plicit subject coreferent with that of the main verb, the infinitive clause  |
|                 | answers a question with $o\dot{u}$ and a direct object N1  |
| (binary)        | Example : Où Luc emmène-t-il Marie ? - Il emmène Marie voir un film  |
| 'P', V N0 à N2  | The sentential complement N1 can take the form of direct speech and  |
|                 | appear in the beginning of the sentence; the subject is after the verb   |
| (binary)        | Example : "Je vais au cinéma", répond Luc à Léa  |
| par N4          | Additional locative object introduced by the preposition par and inter-  |
|                 | preted as a place of passage   |
| (binary)        | Example: Luc passe le lit de la chambre dans le salon par le couloir   |
| Ppv =: en       | Clitic pronominalization of an object introduced by the preposition $de$   |
|                 | into en  |
| (binary)        | Example : Max a dépouillé Ida de ses biens = Max en a dépouillé Ida;   |
|                 | L'au gicla du tonneau = L'eau en gicla; Luc reçoit un colis de Marie =   |
|                 | Luc en reçoit un colis   |
| Ppv =: en figé  | The clitic pronoun $en$ is frozen with the verb $V$  |
| (binary)        | Example : Je n'en reviens pas de ce culot ; Luc s'en va  |
| Ppv =: la figé  | The clitic pronoun $la$ is frozen with the verb $V$  |
| (binary)        | Example : Fermez-la  |
| Ppv =: le       | Clitic pronominalization of a direct object N1 into le   |
| (binary)        | Example: $Paul\ compare\ Luc\ \grave{a}\ un\ singe = Paul\ le\ compare\ \grave{a}\ un\ singe;$                             |
|                 | Luc a bâti cette maison = Luc l'a bâtie; On a élu Luc président = On   |
|                 | l' a élu président   |
| Ppv =: le figé  | The clitic pronoun $en$ is frozen with the verb $V$  |
| (binary)        | Example: Je n'en reviens pas de ce culot; Luc s'en va  |
| Ppv =: les figé | The clitic pronoun <i>les</i> is frozen with the verb V  |
| (binary)        | Example: Max les aligne à Luc  |
| Ppv =: lui      | Clitic pronominalization of an object introduced by the preposition $\hat{a}$  |
| (1:             | into lui   |
| (binary)        | Example : Luc obéit à Léa = Luc lui obéit; Paul consacre de l'argent à   |
| Ppv =: Neg      | son jardin = Paul lui consacre de l'argent  The ditie proposer de is frança with the work V composition to a very educate. |
| Ppv =: Neg      | The clitic pronoun $ne$ is frozen with the verb $V$ , even without any adverb of negation                                  |
| (binary)        | Example : Luc n'arrête pas d'être dérangé ; Luc ne saurait dormir ici  |
| Ppv =: se figé  | The clitic pronoun se is frozen with the verb V  |
| (binary)        | Example: Luc se réserve pour la nuit; Luc s'en va  |
| Ppv =: y        | Clitic pronominalization of an object introduced by a preposition into y   |
| (binary)        | Example: Luc obéit à cette loi = Luc y obéit; Luc punaise les notes sur  |
| (Siliary)       | le tableau = Luc y punaise les notes $les notes$   |
| Ppv =: y figé   | The clitic pronoun $y$ is frozen with the verb $V$   |
| (binary)        | Example: Luc y va; Luc s'y croit   |
| Prép N1 = Ppv   | A nominal object Prép N1 can pronominalize into a clitic; the preposition  |
| LICPINI — I PV  | can be empty   |
| (binary)        | Example: $Paul\ est\ pr\`es\ d'une\ catastrophe = Paul\ en\ est\ pr\`es$   |
| (Sillery)       | Example . I was cos pres a and castastropite - I was the cost pres   |

Table E.36: Documentation des propriétés des tables de verbes (36)

| Feature                     | Description of the feature  |
|-----------------------------|---|
| Prép N1 =: à Nq             | An object Prép N1 can have à as its preposition and an abstract noun  |
| Trep ivi —. a ivq           | as its head noun  |
| (binary)                    | Example : Il parvient à la conscience de Max que Luc était son ami  |
| Prép N1 =: dans Ng          | An object Prép N1 can have dans as its preposition and an abstract noun   |
| Trep itt =: dans itq        | as its head noun  |
| (binary)                    | Example : Il intervient dans les négociations que Marie va partir   |
| Prép N1 =: de Ng            | An object Prép N1 can have de as its preposition and an abstract noun   |
| l rep iti . de itq          | as its head noun  |
| (binary)                    | Example: Il est sorti de cette discussion que Luc fera du yoga  |
| Prép N1 =: Prép ce Qu P     | Preposition and ce before a sentential complement N1 in que can be  |
| = Qu P                      | erased  |
| (binary)                    | Example : Luc s'aperçoit de ce que Marie l'a trompé à ce qu'elle est  |
|                             | enceinte = Luc s'aperçoit que Marie l'a trompé à ce qu'elle est enceinte  |
| Prép N1 =: Prép Qu P =      | A sentential complement Prép N1 can pronominalize into a clitic; the  |
| Ppv                         | preposition can be empty  |
| (binary)                    | Example : Paul parvient à ce que Luc l'aide = Paul y parvient; Paul   |
|                             | doute de ce que Luc puisse réussir = Luc en doute; Luc doit que Marie   |
|                             | $reste\ \grave{a}\ son\ physique = Luc\ le\ doit\ \grave{a}\ son\ physique$   |
| Prép N1hum = Ppv            | An object Prép N1, denoting a person, can pronominalize into a clitic;  |
|                             | the preposition can be empty  |
| (binary)                    | Example : Faire ce travail plaît à Paul = Faire ce travail lui plaît ; Luc  |
|                             | se méfie de Paul = Luc s'en méfie ; Luc préfère Marie à Léa = Luc la  |
|                             | préfère à Léa   |
| Prép N1-hum = Ppv           | An object Prép N1, denoting a non-human entity, can pronominalize into  |
|                             | a clitic; the preposition can be empty  |
| (binary)                    | Example : Luc a survécu à cette épreuve = Luc y a survécu ; Paul parle  |
|                             | de ça avec Luc = Paul en parle avec Luc; Luc préfère le vin à l'eau =   |
|                             | Luc le préfère à l'eau  |
| Prép N2 = Prép là           | A sentential complement Prép N2 can be pronominalized into Prép là; if  |
|                             | the preposition is $\grave{a}$ , it is erased   |
| (binary)                    | Example : Max a extrapolé de ce que Léa était absente que Luc était   |
|                             | revenu = Max a extrapolé de là que Luc était revenu; Max ramène l'in-   |
| Duán NO No                  | flation à ce que la production a diminué = Max ramène là l'inflation  |
| Prép N2 =: à Nq             | An object Prép N2 can have à as its preposition and an abstract noun  |
| (hinary)                    | as its head noun  |
| (binary) Prép N2 =: dans Nq | Example : <i>Il intègre à son programme de partir à 3 h</i> An object Prép N2 can have dans as its preposition and an abstract noun |
| riep ivz =. dans ivq        | as its head noun  |
| (binary)                    | Example: Il inclut dans son programme de partir à 3 h   |
| Prép N2 =: de Nq            | An object Prép N2 can have de as its preposition and an abstract noun   |
| Trop NZ —. de Nq            | as its head noun  |
| (binary)                    | Example : Il élimine de son programme que le départ puisse être retardé   |
| Prép N2 =: Prép ce Qu P     | Preposition and ce before a sentential complement N2 in que can be  |
| = Qu P                      | erased  |
| (binary)                    | Example : Luc s'est renseigné auprès de Marie de ce qu'il est invité =  |
| (                           | Luc s'est renseigné auprès de Marie qu'il est invité  |
| Prép N2 =: Prép Qu P =      | A sentential complement Prép N2 can pronominalize into a clitic   |
| Ppv                         |   |
| (binary)                    | Example : On a autorisé Paul à faire ça = On l'y a autorisé ; Luc félicite  |
|                             | Marie d'avoir fait ça = Luc l'en félicite   |
|                             | v - v   |

Table E.37: Documentation des propriétés des tables de verbes (37)

| Feature                  | Description of the feature  |
|--------------------------|---|
| Prép N2 N0 V N1          | An object Prép N2 can appear at the beginning of the sentence                                 |
| (binary)                 | Example: Je tire une conclusion de cela = De cela je tire une conclusion                      |
| Prép N2hum = Ppv         | An object Prép N2, denoting a person, can pronominalize into a clitic                         |
| (binary)                 | Example : Paul a crié à Luc de venir = Paul lui a crié de venir                               |
| Prép N2hum = Ppv =: lui  | An object Prép N2 with a human meaning can be pronominalized into                             |
|                          | the clitic pronoun <i>lui</i>   |
| (binary)                 | Example: Max passe un stylo à Ida = Max lui passe un stylo                                    |
| Prép N2-hum = Ppv        | An object Prép N2, denoting a non-human entity, can pronominalize into                        |
|                          | a clitic  |
| (binary)                 | Example : Paul consacre son temps à l'écriture = Paul y consacre son                          |
| (**, )                   | temps   |
| Prép N2-hum = Ppv =: lui | An object Prép N2 with a non-human meaning can be pronominalized                              |
| Trop 142 main T pt T iai | into the clitic pronoun $lui$   |
| (binary)                 | Example : Paul a consacré ce rayon à ses bouquins sur César = Paul                            |
| (Silicity)               | leur a consacré ce rayon  |
| Prép N3 = Prép là        | A sentential complement Prép N3 can be pronominalized into Prép là ; if                       |
| Trep its = Trep its      | the preposition is $\hat{a}$ , it is erased   |
| (binary)                 | Example: (no Example known)   |
| Prép N3 =: Prép Qu P =   | Clitic pronominalization of a sentential complement Prép N3; the pre-                         |
| Ppv                      | position can be empty   |
| (binary)                 | Example: Max a donné à Luc comme principe qu'il devait avouer =                               |
| (billed y)               | Max l'a donné à Luc comme principe  |
| Prép N3hum = Ppv         | Clitic pronominalization of an object Prép N3 denoting a person; the                          |
| Trep Nonam = 1 pv        | Prép can be empty   |
| (binary)                 | Example: Max a reçu de Luc comme otage un de ses enfants = Max l'a                            |
| (billed y)               | reçu de Luc comme otage   |
| Prép N3-hum = Ppv        | Clitic pronominalization of an object Prép N3 denoting a non-human                            |
| Trop No main T pt        | entity; the Prép can be empty   |
| (binary)                 | Example: Paul a donné à Luc comme travail ce classement = Paul l'a                            |
| (Silicity)               | donné à Luc comme travail   |
| Prép V0-inf W = Ppv      | An infinitive clause taking the form Prép V0-inf W, with an implicit                          |
|                          | subject coreferent to the subject of the main clause, can pronominalize                       |
|                          | into a clitic; the preposition can be empty   |
| (binary)                 | Example: Paul s'empresse de démentir = Paul s'en empresse; Paul                               |
| (Simoly)                 | $court\ chercher\ du\ pastis = Paul\ y\ court$  |
| Prép0 =: de              | The subject can become an object introduced by the preposition $de$                           |
| (binary)                 | Example: Les dauphins abondent dans la baie = La baie abonde de                               |
|                          | dauphins  |
| Prép0 =: en              | The subject can become an object introduced by the preposition <i>en</i>                      |
| (binary)                 | Example: Les dauphins abondent dans la baie = La baie abonde en                               |
|                          | dauphins  |
| Prép1                    | Prepositions of the object N1   |
| (lexical)                | Example: Max va jusqu'à exiger des dommages: jusqu'à; Le verre va                             |
|                          | $tomber: \langle \mathbf{E} \rangle$ ; Qu'Ida est idiote éclate aux yeux de tous : <b>Loc</b> |
| Prép1 =: à               | An object N1 can be introduced by the preposition $\hat{a}$                                   |
| (binary)                 | Example: Paul se mesure à Luc   |
| Prép1 =: avec            | An object N1 can be introduced by the preposition avec  |
| (binary)                 | Example: Paul se mesure avec Luc  |
| Prép1 =: contre          | An object N1 can be introduced by the preposition <i>contre</i>                               |
| (binary)                 | Example: Paul se bat contre Luc   |
| (J /                     |   |

Table E.38: Documentation des propriétés des tables de verbes (38)

| Feature                | Description of the feature   |
|------------------------|--|
| Prép1 =: dans          | An object N1 can be introduced by the preposition dans                       |
| (binary)               | Example: Le si dissone dans cet accord                                       |
| Prép1 =: d'avec        | An object N1 can be introduced by the preposition d'avec                     |
| (binary)               | Example: L'avis de Luc diverge d'avec le consensus                           |
| Prép1 =: de            | An object N1 can be introduced by the preposition de                         |
| · ·                    |  |
| (binary)               | Example: L'avis de Luc diverge du consensus                                  |
| Prép2                  | Prepositions of the object N2  |
| (lexical)              | Example: Max a accrédité auprès des parents la nouvelle que Luc est          |
|                        | mort : auprès de ; Max a encadré dans ce texte que Luc était ab-             |
|                        | sent : Loc ; Max a pour preuve de cela qu'il ne s'est pas montré :           |
| D ( 2 )                | pour+comme   |
| Prép2 =: à             | An object N2 can be introduced by the preposition $\hat{a}$                  |
| (binary)               | Example : Léa compare Luc à un singe ; Paul joue sa voiture à Luc au         |
| D ( 0                  | poker  |
| Prép2 =: auprès de     | An object N2 can be introduced by the preposition auprès de                  |
| (binary)               | Example : Max excuse Léa auprès de Luc de n'être pas venu                    |
| Prép2 =: auprès de = à | The preposition <i>auprès de</i> introducing an object can be substituted by |
|                        | the preposition $\hat{a}$  |
| (binary)               | Example : Paul se vante (auprès de+à) Paul de ce qu'il a gagné               |
| Prép2 =: avec          | An object N2 can be introduced by the preposition avec                       |
| (binary)               | Example : Le maire a marié Paul avec Léa ; Luc aromatise sa soupe            |
|                        | avec du pistou; Paul parie une bouteille avec Luc qu'Eva ne viendra          |
|                        | pas  |
| Prép2 =: contre        | An object N2 can be introduced by the preposition <i>contre</i>              |
| (binary)               | Example : Luc protège sa voiture contre la pluie d'une bâche                 |
| Prép2 =: dans          | An object N2 can be introduced by the preposition dans                       |
| (binary)               | Example : Luc ceinture la ville dans des remparts                            |
| Prép2 =: d'avec        | An object N2 can be introduced by the preposition d'avec                     |
| (binary)               | Example : Le juge a divorcé Paul d'avec Léa                                  |
| Prép2 =: de            | An object $N2$ can be introduced by the preposition $de$                     |
| (binary)               | Example : Luc protège sa voiture de la pluie d'une bâche ; Luc discerne      |
|                        | le vert du rouge ; Luc aromatise sa soupe de pistou                          |
| Prép2 =: en            | An object N2 can be introduced by the preposition en                         |
| (binary)               | Example : Paul a équipé ses soldats en armes légères ; Luc rend cette        |
|                        | expression en anglais dans son texte   |
| Prép2 =: pour          | An object N2 can be introduced by the preposition pour                       |
| (binary)               | Example: Max donne ce texte à Luc pour un chef-d'oeuvre                      |
| Prép3                  | Prepositions of the object N3  |
| (lexical)              | Example : Max désigne Luc à Léa pour faire ce travail : pour ; Max a         |
|                        | reçu de Luc comme garantie qu'il aurait une prime : <e></e>                  |
| Prép3 =: à             | An object N3 can be introduced by the preposition $\hat{a}$                  |
| (binary)               | Example : Paul joue sa voiture à Luc au poker                                |
| Prép3 =: avec          | An object N3 can be introduced by the preposition avec                       |
| (binary)               | Example : Max a protégé sa voiture de la pluie avec une bâche                |
| Prép3 =: comme         | An object N3 can be introduced by the preposition <i>comme</i>               |
| (binary)               | Example : Max donne à Luc ce cheval comme gagnant                            |
| Prép3 =: contre        | An object N3 can be introduced by the preposition <i>contre</i>              |
| (binary)               | Example : La banque a changé à Max son argent contre des dollars             |
| Prép3 =: dans          | An object N3 can be introduced by the preposition dans                       |
| (binary)               | Example: Paul a rendu cette expression en anglais dans son texte             |
| (Dillary)              | Example. I am a remain come expression on uniquits dans son texte            |

Table E.39: Documentation des propriétés des tables de verbes (39)

| Feature                  | Description of the feature   |
|--------------------------|--|
| Prép3 =: de              | An object N3 can be introduced by the preposition de   |
| (binary)                 | Example : Max a costumé Luc en clown d'une combinaison rouge   |
| Prép3 =: en              | An object N3 can be introduced by the preposition en   |
| (binary)                 | Example: Max a traduit ce texte d'anglais en turc  |
| Prép3 =: par             | An object N3 can be introduced by the preposition par  |
| (binary)                 | Example : Max a protégé sa voiture de la pluie par une bâche   |
| Prép3 =: pour            | An object N3 can be introduced by the preposition pour   |
| (binary)                 | Example : Max donne ce texte à Luc pour un chef-d'oeuvre   |
| Prép3 =: sur             | An object N3 can be introduced by the preposition sur  |
| (binary)                 | Example: Max a réduit 30 F à Luc sur le prix de cet objet  |
| Qu N0 V (Adj)            | From a sentential complement in the indicative mood taking the form que N être Adj W, the noun phrase N can be extracted during the formation of a relative clause; the rest of the sentential complement is conserved in the form of Adj W                            |
| (binary)                 | Example : J'ai des doutes sur une opération. L'intéressé certifie que cette opération est véridique = J'ai des doutes sur une opération que l'intéressé certifie véridique   |
| Qu N0 V (être Adj)       | From a sentential complement in the indicative mood taking the form que N être Adj W, the noun phrase N can be extracted during the formation of a relative clause; the rest of the sentential complement becomes an infinitive clause être Adj W                      |
| (binary)                 | Example : J'ai des doutes sur une opération. L'intéressé certifie que cette opération est véridique = J'ai des doutes sur une opération que l'intéressé certifie être véridique  |
| Qu P = de V0-inf W       | A direct sentential complement in the indicative mood, with a subject coreferent to the main subject, can be replaced by an infinitive clause introduced by the preposition $de$ , with an implicit subject coreferent to the main subject                             |
| (binary)                 | Example: Paul feint qu'il a un malaise = Paul feint d'avoir un malaise   |
| Qu P = V0-inf W (binary) | A sentential complement in the indicative mood, with a subject coreferent to the main subject, can be replaced by a non-prepositional infinitive clause with an implicit subject coreferent to the main subject Example: Paul compte qu'il viendra = Paul compte venir |
| Qu Psubj = de V0-inf W   | A direct sentential complement in the subjunctive mood, with a subject coreferent to the main subject, can be replaced by an infinitive clause introduced by the preposition $de$ , with an implicit subject coreferent to the main subject                            |
| (binary)                 | Example : Paul propose à Marie qu'il la conduise = Paul propose à Marie de la conduire   |
| Qu Psubj = de V2-inf W   | A direct sentential complement in the subjunctive mood, with a subject coreferent to an object $N2$ , can be replaced by an infinitive clause introduced by the preposition $de$ , with an implicit subject coreferent to $N2$   |
| (binary)                 | Example : Paul conseille à Luc qu'il parte = Paul conseille à Luc de partir  |

Table E.40: Documentation des propriétés des tables de verbes (40)

| Feature                 | Description of the feature  |
|-------------------------|---|
| Qu Psubj = V0-inf W     | A (possibly theoretical) sentential complement in the subjunctive mood,       |
|                         | with a subject coreferent to the main subject, can be replaced by a non-      |
|                         | prepositional infinitive clause with an implicit subject coreferent to the    |
|                         | main subject  |
| (binary)                | Example: *Paul désire qu'il boive = Paul désire boire                         |
| Qu Psubj =: Qu Ni Vsubj | A type of subject raising: a sentential complement in the subjunctive         |
| W = (Ni) (de Vi-inf W)  | mood taking the form que Ni Vsubj W can be replaced with a constituent        |
| , , ,                   | Ni followed by an infinitive clause Vi-inf W introduced by the preposition    |
|                         | de  |
| (binary)                | Example : Paul empêche que Pierre vienne = Paul empêche Pierre de             |
|                         | venir   |
| Sfx =: age              | A deverbal noun related with V with the suffix -age is used in a sentence     |
| _                       | syntactically and semantically connected to the basic construction            |
| (binary)                | Example : Luc a paillé la chaise d'un paillage rustique                       |
| Sfx =: ment             | A deverbal noun related with V with the suffix -ment is used in a sentence    |
|                         | syntactically and semantically connected to the basic construction            |
| (binary)                | Example : Luc a empierré le chemin d'un empierrement solide                   |
| Sfx =: tion             | A deverbal noun related with V with the suffix -tion is used in a sentence    |
|                         | syntactically and semantically connected to the basic construction            |
| (binary)                | Example : Luc a irrigué son champ d'une irrigation efficace                   |
| Sfx =: ure              | A deverbal noun related with V with the suffix -ure is used in a sentence     |
|                         | syntactically and semantically connected to the basic construction            |
| (binary)                | Example : Paul a épluché les patates de leur peau épaisse (la peau est        |
|                         | une "épluchure"). Luc a doublé son manteau d'une doublure de soie.            |
| sur combien?            | An additional complement introduced by the preposition <i>sur</i> and contai- |
|                         | ning a cardinal numeral as a determiner denotes a portion of the place        |
|                         | involved, and answers a question with sur combien?                            |
| (binary)                | Example : Luc a descendu le Nil sur 300 km; Luc a acheminé les colis          |
|                         | sur~1000~km   |
| Tc =: futur             | The infinitive clause can contain a future adverb while the main verb is      |
|                         | in the present tense  |
| (binary)                | Example : Paul renonce à partir demain ; Il incombe à l'intéressé de          |
|                         | s'inscrire à partir de demain; Luc jubile de se lever tard demain             |
| Tc =: passé             | The infinitive clause can be at a compound tense while the main verb is       |
|                         | in the present tense  |
| (binary)                | Example: Paul engueule Luc d'avoir fait ça; Cela compte pour Luc              |
|                         | d'avoir réussi; Luc jubile d'avoir réussi                                     |
| Tc =: présent           | The infinitive clause can contain a present adverb while the main verb        |
|                         | is in the present tense   |
| (binary)                | Example : Paul passe pour être encore un bon amant                            |
| thèmeN1                 | Prototypical example of a noun which can be the head of the object N1         |
| (lexical)               | Example: Luc applique cette loi; Luc collabore avec l'ennemi                  |
| Tp = Tc                 | A time adverb in the main clause cannot coexist with a semantically           |
|                         | incompatible time adverb in the infinitive clause                             |
| (binary)                | Example: *Paul manque à ce moment de faire une gaffe demain; *Luc             |
|                         | passe en ce moment boire un coup ce soir; *Luc traîne Marie maintenant        |
|                         | voir un film tout à l'heure   |
|                         | I · · · · ·   |

Table E.41: Documentation des propriétés des tables de verbes (41)

| Feature                   | Description of the feature   |
|---------------------------|--|
| trajet                    | Additional locative complement introduced by the preposition <i>sur</i> or <i>le</i> |
| •                         | long de and interpreted as a place of passage; the sentence may denote               |
|                           | either a movement through the passage, or a stative situation where a                |
|                           | person or thing can travel through the passage                                       |
| (binary)                  | Example : L'eau dégouline sur le mur; cf. *Luc parvient de la fenêtre                |
|                           | au balcon sur la corniche; Le rocher avance dans la mer le long de la                |
|                           | falaise  |
| V = convertir en V-n      | Paraphrase of the form N0 convertir/transformer N1 en V-n or N0 faire de             |
|                           | N1 V-n, where V-n is a deverbal noun related to V                                    |
| (binary)                  | Example : Le temps a parcheminé ce manuscrit = Le temps a                            |
|                           | converti/transformé ce manuscrit en parchemin; Paul a déifié Marie                   |
|                           | = Paul a fait de Marie une déesse  |
| V = convertir en V-n      | Form of a deverbal noun morphologically associated with V, used in a                 |
| (forme V-n)               | paraphrase of the form N0 convertir/transformer N1 en V-n or N0 faire de             |
| (remie v m)               | N1 V-n   |
| (lexical)                 | Example : parchemin  |
| V = mettre en V-n         | Paraphrase of the form N0 mettre N1 en V-n, where V-n is a deverbal                  |
| v meetre en v n           | noun related to V  |
| (binary)                  | Example : Paul a bobiné le fil = Paul a mis le fil en bobine                         |
| V = mettre en V-n (forme) | Form of a deverbal noun morphologically associated with V, used in a                 |
| V-n)                      | paraphrase of the form N0 mettre N1 en V-n   |
| (lexical)                 | Example: bobine  |
| V mouvement               | The sentence denotes a movement  |
| (binary)                  | Example : Luc percute le mur ; Luc croise Léa  |
| V statique                | The sentence denotes a stative situation   |
| (binary)                  | Example: Luc habite cette maison; L'avenue croise le boulevard                       |
| V1-inf $W = Ppv$          | An infinitive clause taking the form V1-inf W, with an implicit subject              |
| v1 v pv                   | coreferent to an object N1, can pronominalize into a clitic                          |
| (binary)                  | Example: Paul emmène Marie faire des courses = Paul y emmène Marie                   |
| V-adj                     | Form of the deverbal adjective related to V in the sentence N0 rendre N1             |
| v daj                     | V-adj, or N0 rendre N1 plus V-adj, or N1 être V-adj à N2                             |
| (lexical)                 | On a libéré Paul (E+de ses liens) = On a rendu Paul libre (E+de ses                  |
| (Textreer)                | liens); On a allégé le paquet de 100 $g = Le$ paquet est plus léger de 100           |
|                           | g; On a imperméabilisé ce tissu à l'eau = Ce tissu est imperméable à                 |
|                           | l'eau  |
| Vc =: aimer               | The infinitive clause can contain the verb <i>aimer</i>                              |
| (binary)                  | Example: Cela tombe mal pour Roméo d'aimer Juliette; Luc en vient à                  |
| (                         | aimer Marie  |
| Vc =: avoir               | The infinitive clause can contain the verb avoir                                     |
| (binary)                  | Example: Il en coûte à Luc d'avoir cette voiture; Luc jubile d'avoir une             |
| (                         | voiture  |
| Vc =: devoir              | The infinitive clause can contain the verb devoir                                    |
| (binary)                  | Example : Paul rechigne à devoir faire ça ; Il arrive à Luc de devoir                |
| (                         | consulter son agenda; cf. *Paul demande à devoir faire ça                            |
| Vc =: être                | The infinitive clause can contain the verb être                                      |
| (binary)                  | Example: Il en coûte à Luc d'être ici; Luc jubile d'être ici                         |
| Vc =: pouvoir             | The infinitive clause can contain the verb pouvoir                                   |
| (binary)                  | Example: Il arrive à Luc de pouvoir se lever; Paul aspire à pouvoir faire            |
| (Silvery)                 | ca   |
|                           | Υ <sup>ω</sup>   |

Table E.42: Documentation des propriétés des tables de verbes (42)

| Feature                               | Description of the feature  |
|---------------------------------------|---|
| Vc =: savoir                          | The infinitive clause can contain the verb savoir   |
| (binary)                              | Example : Il manque à Luc de savoir faire rire ; Paul aspire à savoir   |
| · · · · · · · · · · · · · · · · · · · | faire ça  |
| Vc =: vouloir                         | The infinitive clause can contain the verb <i>vouloir</i>   |
| (binary)                              | Example : Il arrive à Luc de vouloir déménager ; Ceci revient pour Luc  |
|                                       | à vouloir déménager   |
| V-n attache                           | Paraphase of the form NO attacher N1 à N2 avec V-n, where V-n is a  |
| V II detache                          | deverbal noun related to V and denoting a tying system  |
| (binary)                              | Example: On a agrafé la feuille bleue sur la feuille rouge = On a attaché   |
| (billiary)                            | la feuille bleue à la feuille rouge avec une agrafe   |
| V-n attache (forme V-n)               | Form of a deverbal noun morphologically associated with V, used in a  |
| V-III attaclie (Ioillie V-II)         | paraphase of the form N0 attacher N1 à N2 avec V-n, denoting a tying  |
|                                       | system  |
| (lorrigol)                            | Example : agrafe  |
| (lexical) V-n chemin                  |   |
| v-n cnemin                            | Semantically related sentence of the form N1 passer par V-n, where V-n  |
| (1:                                   | is a deverbal noun related to V and denoting a path or a place of passage   |
| (binary)                              | Example: Luc canalise l'eau = L'au passe par un canal; Luc draine le  |
|                                       | liquide = Le liquide passe par un drain   |
| V-n chemin (forme V-n)                | Form of a deverbal noun morphologically associated with V, used in a  |
|                                       | semantically related sentence of the form N1 passer par V-n, denoting a   |
|                                       | path or a place of passage  |
| (lexical)                             | Example: canal  |
| V-n instrument                        | Existence of a deverbal noun related to V and denoting an instrument  |
| (binary)                              | Example: Luc balaye la poussière/balai; Luc canonne le bastion/canon;   |
|                                       | Luc tamise la farine/tamis  |
| V-n instrument (forme V-n)            | Form of a deverbal noun morphologically associated with V denoting an   |
|                                       | instrument  |
| (lexical)                             | Example: balai  |
| V-n résultat                          | Semantically related sentence of the form NO faire V-n, where V-n is a  |
|                                       | deverbal noun related to V and denoting the result  |
| (binary)                              | Example : On a ligaturé les deux lèvres de la plaie = On a fait une   |
|                                       | ligature  |
| V-n résultat (forme V-n)              | Form of a deverbal noun morphologically associated with V, used in a  |
| ,                                     | semantically related sentence of the form N0 faire V-n, denoting the result   |
| (lexical)                             | Example: ligature   |
| V-n transport                         | Paraphase of the form N0 transporter N1 (dans+avec) V-n, where V-n is   |
| •                                     | a deverbal noun related to V and denoting a transport mode  |
| (binary)                              | Example: Luc véhicule Marie = Luc transporte Marie (dans+avec) un   |
| · · · · · · · · · · · · · · · · · · · | véhicule; Luc brouette le foin = Luc transporte le foin (dans+avec) une   |
|                                       | brouette  |
| V-n transport (forme V-n)             | Form of a deverbal noun morphologically associated with V, used in a  |
| · · · · · · · · · · · · · · · · · · · | paraphase of the form N0 transporter N1 (dans+avec) V-n, denoting a   |
|                                       | transport mode  |
| (lexical)                             | Example: véhicule   |
| (10111001)                            | - Distriction of the control of the |

Table E.43: Documentation des propriétés des tables de verbes (43)



## Formules définitoires des tables de verbes distributionnels

Les Tab. F.1 à Tab. F.20 représentent la définition formelle de chaque table de verbes qui justifie leur classification. Les tables, accompagnées d'un exemple, sont classées selon un ordre de priorité à appliquer afin de savoir dans quelle table est incluse (ou doit être ajoutée) une entrée. Afin de pouvoir appliquer plus facilement cet ordre de priorité, on peut se référer à l'arbre de classement des verbes, inclus dans l'annexe G. La première distinction est le nombre d'arguments de la construction de base qui peut être compris entre un et quatre. Chaque table est donc associée à sa formule définitoire, composée d'un ensemble de disjonctions, conjonctions et négations de propriétés syntaxico-sémantiques, autrement dit, un ensemble de propriétés séparées par des ou logiques, des et logiques et des négations non. Cette formule contient tout d'abord la construction de base (première ligne), ainsi que les autres propriétés définitoires, chacune séparées par des et logiques. Elle y inclut aussi bien les propriétés définitoires vraies que fausses (introduites par la négation non) pour l'ensemble d'une table, ainsi que les disjonctions de propriétés codées dans les tables. Ces dernières sont représentées par un ensemble de propriétés séparées par des ou logiques, qui signifient qu'au moins une des propriétés parmi l'ensemble est vraie. Un exemple détaillé (non complet) est donné en 5.2.2.

```
Quatre arguments:
(N0 V N1 Loc N2 V1-inf W)
et non (N1 =: Qu Pind)
et non (N1 =: Qu Psubj)
et non (N2 =: Qu Pind)
et non (N2 =: Qu Psubj)
et non (N3 =: Qu Pind)
et non (N3 =: Qu Psubj)
→ 3 (Paul envoie Luc au village faire le marché)
(NO V Prép N1 Prép N2 Prép N3)
et ((N3 =: Qu Pind) ou (N3 =: Qu Psubj))

ightarrow 18 (Ca a servi à Paul de prétexte pour ne pas venir; Paul prétexte une maladie auprès de Luc
pour ne pas venir)
(N0 V N1 Loc N2 source Loc N3 destination)
et (N2 lieu source de N1)
et (N3 lieu de destination de N1)
et non (N1 =: N-hum)
et non (N1 =: Qu Pind)
et non (N1 =: Qu Psubj)
et non (Prép2 =: \langle E \rangle)
et non (N2 =: Qu Pind)
et non (N2 =: Qu Psubj)
et non (Prép3 =: \langle E \rangle)
et non (N3 =: Qu Pind)
et non (N3 =: Qu Psubj)
→ 38LH (On a refoulé Luc de France dans son pays)
(N0 V N1 Loc N2 source Loc N3 destination)
et (N1 =: N-hum)
et (N2 lieu source de N1)
et (N3 lieu de destination de N1)
et non (N1 =: Qu Pind)
et non (N1 =: Qu Psubj)
et non (Prép2 =: \langle E \rangle)
et non (N2 =: Qu Pind)
et non (N2 =: Qu Psubj)
et non (Prép3 =: \langle E \rangle)
et non (N3 =: Qu Pind)
et non (N3 =: Qu Psubj)
→ 38L (Luc transvase le vin de la cuve dans le tonneau)
```

Table F.1: Formules définitoires dans les tables de verbes (1)

```
(N0 V N1 Prép N2 Prép N3)
et non (N1 =: Qu Pind)
et non (N1 =: Qu Psubj)
et non (Prép2 =: \langle E \rangle)
et non (N2 =: Qu Pind)
et non (N2 =: Qu Psubj)
et non (Prép3 =: \langle E \rangle)
et non (N3 =: Qu Psubj)
et non (N3 =: Qu Pind)
et non (N3 =: Qu Psubj)
et (non (N2 lieu source de N1) ou non (N3 lieu de destination de N1))
\rightarrow 38RR (Luc protège le livre contre la pluie d'un plastique)
```

## Trois arguments:

```
(N0 V Loc N1 V0-inf W)
et non (Prép1 =: \langle E \rangle)
et non (N2 =: Qu Pind)
et non (N2 =: Qu Psubj)
et non (N2 =: si P ou si P)
→ 2 (Paul court à la pharmacie chercher de l'aspirine)
(N0 V N1 à N2)
et (N2 =: Nhum)
et non (Prép2 # à)
{\rm et} \ {\rm non} \ (N2 =: Qu \ {\sf Pind})
et non (N2 =: Qu Psubj)
et non (N2 =: V0-inf W)
et non (N2 =: V1-inf W)
et ((N1 =: Qu Pind) ou (N1 =: Qu Psubj) ou (N1 =: si P ou si P))
→ 9 (Paul crie à Léa que tout est fini)
(N0 V N1 à N2)
et non (N1 =: Qu Pind)
et non (N1 =: Qu Psubj)
et non (N1 =: V0-inf W)
et non (Prép2 \# à)
et ((N2 =: Qu Pind) ou (N2 =: Qu Psubj) ou (N2 =: V0-inf W) ou (N2 =: V1-inf W))

ightarrow 11
(Paul dresse Léa à tout ranger)
```

Table F.2: Formules définitoires dans les tables de verbes (2)

```
(N0 V N1 Prép N2)
et non (Prép2 =: \langle E \rangle)
et non (N2 =: Qu Pind)
et non (N2 =: Qu Psubj)
et non (N2 =: V0-inf W)
et non (N2 =: V1-inf W)
et ((N1 =: Qu Pind) ou (N1 =: Qu Psubj))
et ((Prép2 \# à) ou non (N2 =: Nhum))
\rightarrow 10 (Ceci comporte pour Flo qu'elle doit partir tôt)
(N0 V N1 de N2)
et non (N1 =: Qu Pind)
et non (N1 =: Qu Psubi)
et non (N1 =: V0-inf W)
et non (Prép2 # de)
et ((N2 =: Qu Pind) ou (N2 =: Qu Psubj) ou (N2 =: V1-inf W))
→ 13 (Paul informe Luc de ce que Léa arrive)
(N0 V N1 Prép N2)
et non (N1 =: Qu Pind)
et non (N1 =: Qu Psubj)
et non (N1 =: si P ou si P)
et non (N1 =: V0-inf W)
et non (Prép2 # à+de)
et non (N2 lieu source de N1)
et non (N2 lieu de destination de N1)
et non (N2 lieu statique de N1)
et non (N2 =: Qu Pind)
et non (N2 =: Qu Psubj)
et non (N2 =: V0-inf W)
et non (N2 =: V1-inf W)
et non (N0 V N1 et N2)
et ((N2 bénéficiaire) ou (N2 détrimentaire))
→ 36DT (Paul offre des fleurs à Léa; Ida a volé une fleur à Luc; Ida a reçu une fleur de Luc)
```

Table F.3: Formules définitoires dans les tables de verbes (3)

```
(N0 V N1 Prép N2)
{
m et} (N0 V N1 et N2)
et non (N1 =: Qu Pind)
et non (N1 =: Qu Psubj)
et non (N1 =: si P ou si P)
et non (N1 =: V0-inf W)
et non (Prép2 =: \langle E \rangle)
et non (N2 =: Qu Pind)
et non (N2 =: Qu Psubj)
et non (N2 =: V0-inf W)
et non (N2 =: V1-inf W)
et ((N2 lieu source de N1) ou (N2 lieu de destination de N1))
\rightarrow 36SL (Luc colle la fiche bleue sur la fiche jaune)
(N0 V N1 Prép N2)
et (N0 V N1 et N2)
et non (N1 =: Qu Pind)
et non (N1 =: Qu Psubj)
et non (N1 =: si P ou si P)
et non (N1 =: V0-inf W)
et non (Prép2 =: \langle E \rangle)
et non (N2 lieu source de N1)
et non (N2 lieu de destination de N1)
et non (N2 =: Qu Pind)
et non (N2 =: Qu Psubj)
et non (N2 =: V0-inf W)
et non (N2 =: V1-inf W)
\rightarrow 36S (Luc compare Guy (à+avec+et) Louis)
```

Table F.4: Formules définitoires dans les tables de verbes (4)

```
(N0 V N1 à N2)
et non (N0 V N1 et N2)
et non (N1 =: Qu Pind)
et non (N1 =: Qu Psubj)
et non (N1 =: si P ou si P)
et non (N1 =: V0-inf W)
et non (N1 lieu de destination de N0)
et non (N2 lieu source de N1)
et non (N2 lieu de destination de N1)
et non (N2 lieu statique de N1)
et non (Prép2 # à)
et non (N2 bénéficiaire)
et non (N2 détrimentaire)
et non (N2 =: Qu Pind)
et non (N2 =: Qu Psubj)
et non (N2 =: V0-inf W)
et non (N2 =: V1-inf W)
et non (N2 =: Npl obl)
\rightarrow 36R (Luc conjugue le verbe au futur)
(N0 V N1 de N2)
et non (N1 =: Qu Pind)
et non (N1 =: Qu Psubj)
et non (N1 =: si P ou si P)
et non (N1 =: V0-inf W)
et non (Prép2 =: a+<E>)
et non (N2 =: Qu Pind)
et non (N2 =: Qu Psubj)
et non (N2 =: V0-inf W)
et non (N2 =: V1-inf W)
et non (N2 lieu source de N0)
et non (N2 lieu source de N1)
et non (N2 lieu de destination de N1)
et non (N2 lieu statique de N1)
et non (N2 bénéficiaire)
et non (N2 détrimentaire)
et non (N0 V N1 et N2)
et ((N1 lieu source de N2) ou (N1 détrimentaire))
→ 37E (Luc débarrasse le salon de tous les meubles)
```

Table F.5: Formules définitoires dans les tables de verbes (5)

```
(N0 V N1 Prép N2)
et (Prép2 =: de)
et (N1 bénéficiaire)
et non (N1 =: Qu Pind)
et non (N1 =: Qu Psubj)
et non (N1 =: V0-inf W)
et non (Prép2 =: a+<E>)
et non (N2 =: Qu Pind)
et non (N2 =: Qu Psubj)
et non (N2 =: V1-inf W)
et non (N2 lieu source de N0)
et non (N2 lieu source de N1)
et non (N2 lieu de destination de N1)
et non (N2 lieu statique de N1)
et non (N2 bénéficiaire)
et non (N2 détrimentaire)
et non (N0 V N1 et N2)
\rightarrow 37M1 (L'héritage a nanti Luc d'une fortune)
(N0 V N1 Prép N2)
et (Prép2 =: de)
et (N1 lieu de destination de N2)
et non (N1 =: Qu Pind)
et non (N1 =: Qu Psubj)
et non (N1 =: V0-inf W)
et non (Prép2 =: \grave{a} + \langle E \rangle)
{\rm et} \ {\rm non} \ (N2 =: Qu \ Pind)
et non (N2 =: Qu Psubj)
et non (N2 =: V1-inf W)
et non (N2 lieu source de N0)
et non (N2 bénéficiaire)
et non (N2 détrimentaire)
et non (N0 V N1 et N2)
→ 37M2 (Luc a hachuré la feuille de traits rouges)
→ 37M3 (Luc a labouré le terrain de profonds sillons)
→ 37M4 (Luc a jonché le sol de papiers gras)
→ 37M5 (On a goudronné la route d'une épaisse couche de goudron)
→ 37M6 (On a gainé le fil d'une gaine de plastique rouge)
```

Table F.6: Formules définitoires dans les tables de verbes (6)

```
(N0 V N1 Loc N2 destination)
et (N2 lieu de destination de N1)
et non (N1 =: N-hum)
et non (N1 =: Qu Pind)
et non (N1 =: Qu Psubj)
et non (N1 =: si P ou si P)
et non (N1 =: V0-inf W)
et non (N1 lieu de destination de N0)
et non (Prép2 =: \langle E \rangle)
et non (N2 =: Qu Pind)
et non (N2 =: Qu Psubj)
et non (N2 =: V0-inf W)
et non (N2 =: V1-inf W)
et non (N2 =: Npl obl)
et non (N0 V N1 et N2)
→ 38LHD (On a relégué Max outre-mer)
(N0 V N1 Loc N2 source)
et (N2 lieu source de N1)
et non (N1 =: N-hum)
et non (N1 =: Qu Pind)
et non (N1 =: Qu Psubj)
et non (N1 =: si P ou si P)
et non (N1 =: V0-inf W)
et non (N1 lieu de destination de N0)
et non (Prép2 =: \langle E \rangle)
et non (N2 =: Qu Pind)
et non (N2 =: Qu Psubj)
et non (N2 =: V0-inf W)
et non (N2 =: V1-\inf W)
et non (N2 =: Npl obl)
et non (N0 V N1 et N2)
→ 38LHS (Le choc a désarçonné Max de son cheval)
(N0 V N1 Loc N2)
et (N2 lieu statique de N1)
et non (N1 =: N-hum)
et non (N1 =: Qu Pind)
et non (N1 =: Qu Psubi)
et non (N1 =: si P ou si P)
et non (N1 =: V0-inf W)
et non (N1 lieu de destination de N0)
et non (Prép2 =: \langle E \rangle)
et non (N2 =: Qu Pind)
et non (N2 =: Qu Psubj)
et non (N2 =: V0-inf W)
et non (N2 =: V1-inf W)
et non (N2 =: Npl obl)
et non (N0 V N1 et N2)
→ 38LHR (Max héberge Luc dans son studio)
```

Table F.7: Formules définitoires dans les tables de verbes (7)

```
(N0 V N1 Loc N2 destination)
et (N1 =: N-hum)
et (N2 lieu de destination de N1)
et non (N1 =: Qu Pind)
et non (N1 =: Qu Psubj)
et non (N1 =: si P ou si P)
et non (N1 =: V0-inf W)
et non (N1 lieu de destination de N0)
et non (Prép2 =: \langle E \rangle)
et non (N2 =: Qu Pind)
et non (N2 =: Qu Psubj)
et non (N2 =: V0-inf W)
et non (N2 =: V1-inf W)
et non (N2 =: Npl obl)
et non (N0 V N1 et N2)

ightarrow 38LD (Luc a déposé le paquet sur le lit)
(N0 V N1 Loc N2 source)
et (N1 =: N-hum)
et (N2 lieu source de N1)
et non (N1 =: Qu Pind)
et non (N1 =: Qu Psubj)
et non (N1 =: si P ou si P)
et non (N1 =: V0-inf W)
et non (N1 lieu de destination de N0)
et non (Prép2 =: \langle E \rangle)
et non (N2 =: Qu Pind)
et non (N2 =: Qu Psubj)
et non (N2 =: V0-inf W)
et non (N2 =: V1-inf W)
et non (N2 =: Npl obl)
et non (N0 V N1 et N2)
\rightarrow 38LS (Luc a ôté le livre du lit)
(N0 V N1 Loc N2)
et (N1 =: N-hum)
et (N2 lieu statique de N1)
et non (N1 =: Qu Pind)
et non (N1 =: Qu Psubj)
et non (N1 =: si P ou si P)
et non (N1 =: V0-inf W)
et non (N1 lieu de destination de N0)
et non (Prép2 =: \langle E \rangle)
et non (N2 =: Qu Pind)
et non (N2 =: Qu Psubj)
et non (N2 =: V0-inf W)
et non (N2 =: V1-inf W)
et non (N2 =: Npl obl)
et non (N0 V N1 et N2)
\rightarrow 38LR (Luc conserve son vin dans le grenier)
```

Table F.8: Formules définitoires dans les tables de verbes (8)

```
(N0 V N1 en N2)
et (N2 être V-n)
et non (N1 =: Qu Pind)
et non (N1 =: Qu Psubj)
et non (N1 =: V0-inf W)
et non (N1 =: si P ou si P)
et non (N1 lieu de destination de N0)
et non (Prép2 # en)
et non (N2 lieu source de N1)
et non (N2 lieu de destination de N1)
et non (N2 lieu statique de N1)
et non (N2 =: Npl obl)
et non (N0 V N1 et N2)
→ 32CV (Ce procédé caramélise le sucre en une pâte aromatique)
(N0 V N1 en N2)
et (N2 =: Npl obl)
et non (N1 =: Qu Pind)
et non (N1 =: Qu Psubj)
et non (N1 =: si P ou si P)
et non (N1 =: V0\text{-inf }W)
et non (N1 lieu de destination de N2)
et non (N1 lieu source de N2)
et non (N1 bénéficiaire)
et non (N1 détrimentaire)
et non (Prép2 # en+entre)
et non (N2 =: Qu Pind)
et non (N2 =: Qu Psubj)
et non (N2 =: V0-inf W)
et non (N2 =: V1-inf W)
et non (N0 V N1 et N2)
→ 38PL (Luc a coupé le gâteau en trois parts)
```

Table F.9: Formules définitoires dans les tables de verbes (9)

```
(N0 V N1 Prép N2)
et (Prép2 # à)
et non (N1 =: Qu Pind)
et non (N1 =: Qu Psubj)
et non (N1 =: si P ou si P)
et non (N1 =: V0-inf W)
et non (N1 lieu de destination de N0)
et non (N1 lieu de destination de N2)
et non (N1 lieu source de N2)
et non (N1 bénéficiaire)
et non (N1 détrimentaire)
et non (N2 lieu source de N1)
et non (N2 lieu de destination de N1)
et non (N2 lieu statique de N1)
et non (Prép2 =: \langle E \rangle)
et non (N2 bénéficiaire)
et non (N2 détrimentaire)
et non (N2 =: Qu Pind)
et non (N2 =: Qu Psubj)
et non (N2 =: V0-inf W)
et non (N2 =: V1-inf W)
et non (N0 V N1 et N2)
et (\text{non } (\text{Prép2} =: \text{en}) \text{ ou } (\text{non } (\text{N2} =: \text{Npl obl}) \text{ et non } (\text{N2 } \text{être V-n})))
→ 38R (Luc a prévenu Guy contre ce genre de type)
(N0 V Loc N1 V0-inf W)
et (Prép1 =: \langle E \rangle)
→ 2T (Paul dévale l'escalier chercher Marie)
(N0 V N1 Prép N2)
et (Prép2 =: \langle E \rangle)
et non (N1 =: V0-inf W)
et non (Prép2 # <E>+comme)
et non (N2 =: V0-inf W)
\rightarrow 39 (On a élu Guy président)
(N0 V à N1 Prép N2)
et non (Prép1 # à)
et non (Prép2 # avec+pour)
et non (N2 =: Qu Pind)
et non (N2 =: Qu Psubj)
et non (N2 =: V1-inf W)
et ((N1 =: Qu Pind) ou (N1 =: Qu Psubj))
→ 14 (Cette règle équivant pour Paul à ce que Léa soit élue)
```

Table F.10: Formules définitoires dans les tables de verbes (10)

```
(N0 V de N1 Prép N2)
et non (Prép1 # de)
et non (Prép2 =: \langle E \rangle)
et non (N2 =: Qu Pind)
et non (N2 =: Qu Psubj)
et non (N2 =: V1-inf W)
et ((N1 =: Qu Pind) ou (N1 =: Qu Psubj))
→ 15 (Paul répond devant le juge de ce que Léa a fauté)
(N0 V Prép N1 Prép N2)
et non (Prép2 =: \langle E \rangle)
et ((N1 =: Qu Pind) ou (N1 =: Qu Psubj) ou (non (N1 =: V0-inf W) et ((Prép1 # <E>) ou (non
(Prép2 =: à) et non (Prép2 =: de))) et ((Prép1 # avec+pour) ou non (Prép2 =: à))))
et ((N2 =: Qu Pind) ou (N2 =: Qu Psubj) ou (N2 =: V1-inf W))

ightarrow 16 (Flo déduit que Guy est arrivé de ce qu'il y a du désordre; Flo engage Guy pour danser;
Flo apprend à Guy à danser)
(N0 V Loc N1 source Loc N2 destination)
et (N1 lieu source de N0)
et (N2 lieu de destination de N0)
et non (Prép1 =: \langle E \rangle)
et non (N1 =: Qu Pind)
et non (N1 =: Qu Psubj)
et non (N1 =: V0-inf W)
et non (N1 =: V2-inf W)
et non (N2 =: Qu Pind)
et non (N2 =: Qu Psubj)
et non (N2 =: si P ou si P)
et non (N0 V N1 et N2)
\rightarrow 35L (Luc passe du salon à la cuisine)
(N0 V Prép N1 Prép N2)
et non (Prép1 =: \langle E \rangle)
et non (N1 =: Qu Pind)
et non (N1 =: Qu Psubj)
et non (N1 =: V2-inf W)
et non (Prép2 =: \langle E \rangle)
et non (N2 =: Qu Pind)
et non (N2 =: Qu Psubj)
et non (N2 =: V1-inf W)
et (non (N1 lieu source de N0) ou non (N2 lieu de destination de N0))
\rightarrow 35RR (Léa change de voiture avec Luc)
```

Table F.11: Formules définitoires dans les tables de verbes (11)

## Deux arguments:

```
(N0 V N1)
et (N0 =: Qu P)
et (N1 =: Nhum)
et non (N1 =: Nconc)
et non (N1 =: Npc)
et non (N1 =: V0-inf W)
et non (Qu Psubj =: Qu Ni Vsubj W = (Ni) (de V-inf W))
et non [extrap]
et ((N0 =: V1-inf W) ou (non (N1 =: Qu Pind) et non (N1 =: Qu Psubj) et non (N1 =: si P ou si
P) et non (N1 =: combien P)))

ightarrow 4 (Que Paul vienne amuse Luc; Que les enfants soient ensemble neutralise qu'ils soient agités)
(N0 V N1)
et non (N0 =: V1-inf W)
et non (Qu Psubj =: Qu Ni Vsubj W = (Ni) (de V-inf W))
et ((N1 =: Qu Pind) ou (N1 =: Qu Psubj) ou (N1 =: si P ou si P) ou (N1 =: combien P))
→ 6 (Paul estime que Luc a raison; Luc contemple combien le ciel est beau)
(N0 V N1)
et (N1 =: Qu Psubj)
et (Qu Psubj =: Qu Ni Vsubj W = (Ni) (de Vi-inf W))
→ 12 (Paul apprécie (que Léa l'ait aidé+Léa de l'avoir aidé)
(N0 V N1)
et (thèmeN1)
et [passif par]
et non (N0 =: Qu P)
et non (N1 =: Qu Pind)
et non (N1 =: Qu Psubj)
et non (N1 =: si P ou si P)
et non (N1 =: combien P)
et non (N1 =: V0-inf W)
et non (N0 lieu source de N1)
et non (N0 lieu de destination de N1)
et non (N0 lieu statique de N1)
et non (N1 lieu source de N0)
et non (N1 lieu de destination de N0)
et non (N1 lieu statique de N0)
et non (N1 lieu de passage de N0)
→ 32R3 (Luc a brisé ses chaussures; Cet appareil adoucit l'eau)
```

Table F.12: Formules définitoires dans les tables de verbes (12)

```
(N0 V N1)
et [passif par]
et non (N1 =: Qu Pind)
et non (N1 =: Qu Psubj)
et non (N1 =: si P ou si P)
et non (N1 =: combien P)
et non (N1 =: V0-inf W)
et non (thèmeN1)
et non (N1 apparition)
et non (N1 disparition)
et non (N1 =: Npl obl)
et non (N0 lieu source de N1)
et non (N0 lieu de destination de N1)
et non (N0 lieu statique de N1)
et non (N1 lieu source de N0)
et non (N1 lieu de destination de N0)
et non (N1 lieu statique de N0)
et non (N1 lieu de passage de N0)
et ((N0 rendre N1 V-adj) ou (N0 rendre N1 plus V-adj))
et ((N1 =: Nconc) \text{ ou non } (N0 =: Qu P) \text{ ou non } (N1 =: Nhum))
\rightarrow 32RA (Ce rideau assombrit la pièce)
(N0 V N1)
et (N1 apparition)
et [passif par]
et non (N0 =: Qu P)
et non (N1 =: Qu Pind)
et non (N1 =: Qu Psubj)
et non (N1 =: si P ou si P)
et non (N1 =: combien P)
et non (N1 =: V0-inf W)
et non (th\`{e}meN1)
\rightarrow 32A (Luc construit une cabane)
(N0 V N1)
et (N1 disparition)
et [passif par]
et non (N0 =: Qu P)
et non (N1 =: Qu Pind)
et non (N1 =: Qu Psubj)
et non (N1 =: si P ou si P)
et non (N1 =: combien P)
et non (N1 =: V0-inf W)
et non (thèmeN1)
\rightarrow 32D (L'explosion a soufflé le bar)
```

Table F.13: Formules définitoires dans les tables de verbes (13)

```
(N0 V N1)
et (N1 =: Npl obl)
et [passif par]
et non (N0 =: Qu P)
et non (N1 =: Qu Pind)
et non (N1 =: Qu Psubj)
et non (N1 =: si P ou si P)
et non (N1 =: combien P)
et non (N1 =: V0-inf W)
et non (thèmeN1)
et non (N1 apparition)
et non (N1 disparition)
\rightarrow 32PL (Luc entasse les cubes)
(N0 V N1)
et (N1 =: Nhum)
et [passif par]
et non (N0 =: Qu P)
et non (N1 =: Qu Pind)
et non (N1 =: Qu Psubj)
et non (N1 =: si P ou si P)
et non (N1 =: combien P)
et non (N1 =: V0-inf W)
et non (thèmeN1)
et non (N1 =: N-hum)
et non (N1 apparition)
et non (N1 disparition)
et non (N1 =: Npl obl)
et non (N0 rendre N1 V-adj)
et non (N0 rendre N1 plus V-adj)
\rightarrow 32H (Luc a violé Ida)
(N0 V N1)
et non (N0 =: Qu P)
et non (N1 =: Qu Pind)
et non (N1 =: Qu Psubj)
et non (N1 =: si P ou si P)
et non (N1 =: combien P)
et non (N1 =: V0-inf W)
et non [passif par]
et non [passif de]
et non (N0 lieu source de N1)
et non (N0 lieu de destination de N1)
et non (N0 lieu statique de N1)
et non (N1 lieu source de N0)
et non (N1 lieu de destination de N0)
et non (N1 lieu statique de N0)
et non (N1 lieu de passage de N0)
\rightarrow 32NM (Le sac pèse 10 kg)
```

Table F.14: Formules définitoires dans les tables de verbes (14)

```
(N0 V N1)
et (N1 =: N-hum)
et non (N0 =: Qu P)
et non (N1 =: Qu Pind)
et non (N1 =: Qu Psubj)
et non (N1 =: si P ou si P)
et non (N1 =: combien P)
et non (N1 =: V0-inf W)
et non (N1 apparition)
et non (N1 disparition)
et non (N1 =: Npl obl)
{
m et} ((N0 lieu source de N1) {
m ou} (N0 lieu de destination de N1) {
m ou} (N0 lieu statique de N1))
\rightarrow 38L0 (Luc a inhalé le gaz)
(N0 V N1)
et (N1 =: N-hum)
et non (N0 =: Qu P)
et non (N1 =: Qu Pind)
et non (N1 =: Qu Psubj)
et non (N1 =: si P ou si P)
et non (N1 =: combien P)
et non (N1 =: V0-inf W)
{
m et\ non\ }({
m N1\ apparition})
et non (N1 disparition)
et non (N1 =: Npl obl)
et ((N1 lieu source de N0) ou (N1 lieu de destination de N0) ou (N1 lieu statique de N0)
ou (N1 lieu de passage de N0))
et ((N1 être Vpp W) ou non (N0 V N1 Loc N1pc W) ou non (N1 =: Npc) ou non [passif par])
\rightarrow 38L1 (Luc gagne la porte)
```

Table F.15: Formules définitoires dans les tables de verbes (15)

```
(N0 V N1)
et (N0 V N1 Loc N1pc W)
et (N1 =: Npc)
et [passif par]
et non (N0 =: Qu P)
et non (N1 =: Qu Pind)
et non (N1 =: Qu Psubj)
et non (N1 =: si P ou si P)
et non (N1 =: combien P)
et non (N1 =: V0-inf W)
et non (N1 =: Nabs)
et non (thèmeN1)
et non (N1 apparition)
et non (N1 disparition)
et non (N1 =: Npl obl)
et non (N0 lieu source de N1)
et non (N0 lieu de destination de N1)
et non (N0 lieu statique de N1)
et non (N0 rendre N1 V-adj)
et non (N0 rendre N1 plus V-adj)
et non (N1 être Vpp W)
→ 32CL (Luc embrasse (le front de Léa+Léa sur le front))
(N0 V N1)
et (N1 =: N-hum)
et [passif par]
et non (N0 =: Qu P)
et non (N1 =: Qu Pind)
et non (N1 =: Qu Psubj)
et non (N1 =: si P ou si P)
et non (N1 =: combien P)
et non (N1 =: V0-inf W)
et non (N1 =: Nabs)
et non (thèmeN1)
et non (N1 apparition)
et non (N1 disparition)
et non (N1 =: Npl obl)
et non (N0 lieu source de N1)
et non (N0 lieu de destination de N1)
et non (N0 lieu statique de N1)
et non (N1 lieu source de N0)
et non (N1 lieu de destination de N0)
et non (N1 lieu statique de N0)
et non (N1 lieu de passage de N0)
et non (N0 rendre N1 V-adj)
et non (N0 rendre N1 plus V-adj)
et ((N1 être Vpp W) ou non (N0 V N1 Loc N1pc W) ou non (N1 =: Npc))
\rightarrow 32C (Luc a abîmé le livre)
```

Table F.16: Formules définitoires dans les tables de verbes (16)

```
(N0 V N1)
et (N1 =: Nabs)
et (N0 V (N1 de N1c) = N0 V (N1c) (Prép N1))
et [passif par]
et non (N0 =: Qu P)
et non (N1 =: Qu Pind)
et non (N1 =: Qu Psubj)
et non (N1 =: si P ou si P)
et non (N1 =: combien P)
et non (N1 =: V0-inf W)
et non (thèmeN1)
et non (N1 apparition)
et non (N1 disparition)
et non (N1 =: Npl obl)
et non (N0 lieu source de N1)
et non (N0 lieu de destination de N1)
et non (N0 lieu statique de N1)
et non (N1 lieu source de N0)
et non (N1 lieu de destination de N0)
et non (N1 lieu statique de N0)
et non (N1 lieu de passage de N0)
et non (N0 rendre N1 V-adj)
et non (N0 rendre N1 plus V-adj)
→ 32R1 (Luc singe (les attitudes de Léa+Léa dans ses attitudes))
(N0 V N1)
et (N1 =: Nabs)
et [passif par]
et non (N0 =: Qu P)
et non (N1 =: Qu Pind)
et non (N1 =: Qu Psubj)
et non (N1 =: si P ou si P)
et non (N1 =: combien P)
et non (N1 =: V0-inf W)
et non (thèmeN1)
et non (N1 apparition)
et non (N1 disparition)
et non (N1 =: Npl obl)
et non (N0 lieu source de N1)
et non (N0 lieu de destination de N1)
et non (N0 lieu statique de N1)
et non (N1 lieu source de N0)
et non (N1 lieu de destination de N0)
et non (N1 lieu statique de N0)
et non (N1 lieu de passage de N0)
et non (N0 V (N1 de N1c) = N0 V (N1c) (Prép N1))
et non (N0 rendre N1 V-adj)
et non (N0 rendre N1 plus V-adj)
\rightarrow 32R2 (Luc brandit le livre; Luc copie un texte)
```

Table F.17: Formules définitoires dans les tables de verbes (17)

```
(N0 V Prép V0-inf W)
et non (N1 =: Qu Pind)
et non (N1 =: Qu Psubj)
et non (N1 =: si P ou si P)
et non (N1 =: combien P)
\rightarrow 1 (Paul cesse de travailler; Paul cesse le travail; *Paul cesse que Marie travaille)
(N0 V Prép N1)
et (N0 =: Qu P)
et [extrap]
et non (N1 =: Qu Pind)
et non (N1 =: Qu Psubj)
et non (N1 =: V0-inf W)
et non (N0 rendre N1 V-adj)
et non (N0 rendre N1 plus V-adj)
→ 5 (Que Marie vienne importe à Paul; Il importe à Paul que Marie vienne)
(N0 V à N1)
et non (Prép1 # à)
et ((N1 =: Qu Pind) ou (N1 =: Qu Psubj))
\rightarrow 7 (Paul consent à ce que Marie fasse ça)
(N0 V de N1)
et non (Prép1 # de)
et ((N1 =: Qu Pind) ou (N1 =: Qu Psubj))
\rightarrow 8 (Paul s'insurge de ce que Marie ait fait ça)
(N0 V à N1)
et non (Prép1 # à)
et non (N1 =: Qu Pind)
et non (N1 =: Qu Psubj)
et non (N1 =: V0-inf W)
et non (N1 = où)
et non (N1 lieu source de N0)
et non (N1 lieu de destination de N0)
et non (N1 lieu statique de N0)
et (non (N0 =: Qu P) ou non [extrap])
\rightarrow 33 (Paul compatit à mes problèmes)
(N0 V Prép N1)
et (Prép1 =: avec)
et (N0 et N1 V)
et non (N1 =: Qu Pind)
et non (N1 =: Qu Psubj)
et non (N1 =: V0-inf W)
et (non (N0 =: Qu P) ou non [extrap])
→ 35S (Paul flirte avec Marie; Paul et Marie flirtent)
```

Table F.18: Formules définitoires dans les tables de verbes (18)

```
(N0 V Prép N1)
et (Prép1 # \dot{a}+<E>)
et non (N1 = où)
et non (N1 lieu source de N0)
et non (N1 lieu de destination de N0)
et non (N1 lieu statique de N0)
et non (N0 et N1 V)
et (non (N0 =: Qu P) ou non [extrap])
et ((non (N1 =: Qu Pind) et non (N1 =: Qu Psubj)) ou ((Prép1 # à) et (Prép1 # de)))
et ((N1 =: Qu \text{ Pind}) \text{ ou } (N1 =: Qu \text{ Psubj}) \text{ ou non } (N1 =: V0\text{-inf } W))
→ 35R (Ça a dégénéré en bagarre; Paul dîne d'une salade)
(N0 V Loc N1 source)
et (N1 lieu source de N0)
et non (N0 =: Qu P)
et non (N1 =: Qu Pind)
et non (N1 =: Qu Psubj)
et non (N1 =: V0-inf W)
et non (N0 et N1 V)
et non (N1 V de N0)
→ 35LS (Ce vin provient de Carnas)
(N0 V Loc N1 destination)
et (N1 lieu de destination de N0)
et non (N1 =: Qu Pind)
et non (N1 =: Qu Psubj)
et non (N1 =: V0-inf W)
et non (N0 et N1 V)
et (non (N0 =: Qu P) ou non [extrap])
\rightarrow 35LD (Le bateau accoste au quai)
(N0 V Loc N1)
et (N1 V de N0)
et non (N1 =: Qu Pind)
et non (N1 =: Qu Psubj)
et non (N1 =: V0-inf W)
et non (N0 et N1 V)
et (non (N0 =: Qu P) ou non [extrap])
et ((N1 lieu source de N0) ou (N1 lieu statique de N0))
\rightarrow 34L0 (Les abeilles grouillent dans le jardin = Le jardin grouille d'abeilles)
```

Table F.19: Formules définitoires dans les tables de verbes (19)

```
(N0 V Loc N1)
et (N1 lieu statique de N0)
et non (N1 =: Qu Pind)
et non (N1 =: Qu Psubj)
et non (N1 =: V0-inf W)
et non (N0 et N1 V)
et non (N1 V de N0)
et (non (N0 =: Qu P) ou non [extrap])
→ 35ST (Le pieu sort de l'eau; Le chemin aboutit chez moi)
(N0 V Loc N1)
et (N1 = où)
et non (N1 lieu source de N0)
et non (N1 lieu de destination de N0)
et non (N1 lieu statique de N0)
et non (N1 =: Qu Pind)
et non (N1 =: Qu Psubj)
et non (N1 =: V0-inf W)
et non (N0 \text{ et } N1 \text{ V})
et non (N1 V de N0)
et (non (N0 =: Qu P) ou non [extrap])
\rightarrow 35LR (Paul farfouille dans le sac)
Un argument:
(N0 V)
et (N0 =: Nhum)
et non (N0 =: N-hum)
\rightarrow 31H (Paul patiente)
(N0 V)
et (N0 =: N-hum)
\rightarrow 31R ((Paul+la terre) tremble; Un accident s'est produit)
```

Table F.20: Formules définitoires dans les tables de verbes (20)

 $Annexe\ F\ Formules\ définitoires\ des\ tables\ de\ verbes\ distributionnels$ 



# Arbre de classement des verbes distributionnels

# G.1 Conventions de lecture de l'arbre

# G.1.1 Objectif

L'arbre de classement (Fig. G.1 à Fig. G.7) sert à déterminer à quelle classe appartient une entrée verbale donnée. Il est conçu pour un utilisateur qui connaît les propriétés de l'entrée et qui applique successivement les critères indiqués dans l'arbre.

# G.1.2 Constructions prises en compte

Presque tous les critères concernent la construction qui comporte le sujet et tous les compléments essentiels, et que nous appelons construction de base (cf. 5.2.2). Par exemple, pour transvaser, la construction de base est illustrée par la phrase Luc transvase le vin de la cuve dans le tonneau, qui a un complément direct et deux compléments prépositionnels. Quelques critères concernent des variantes de la construction de base, par exemple On élit Luc comme président / On élit Luc président, et d'autres encore des constructions totalement différentes dans laquelle les arguments occupent d'autres positions, comme Le vin est transvasé par Luc de la cuve dans le tonneau.

#### G.1.3 Détermination de la construction de base

Avant d'utiliser l'arbre de classement sur une entrée, l'utilisateur détermine sa construction de base, car c'est celle-ci qui servira de référence pour l'application de

la plupart des critères. La construction de base est choisie parmi les différentes constructions qui relèvent de l'entrée, et dans lesquelles le verbe conserve le même sens. Ce choix peut être délicat et même en partie arbitraire, mais il repose sur des priorités :

- priorité à la construction qui comporte le plus de compléments essentiels, par exemple *Luc conjugue le verbe au futur* par rapport à *Luc conjugue le verbe*;
- priorité à l'actif par rapport au passif, même lorsqu'il est moins employé, par exemple Le paysage éberlue Max par rapport à Max est éberlué par le paysage;
- priorité à la construction qui comporte une préposition par rapport à celle sans préposition, par exemple On élit Luc comme président par rapport à On élit Luc président;
- priorité à la complétive sur l'infinitive, par exemple Luc craint qu'il ne pleuve par rapport à Luc craint d'être mouillé, et donc complément direct;
- lorsqu'une construction contient deux compléments essentiels dont l'un dénote un lieu, et situe par rapport à ce lieu une entité dénotée par l'autre complément, priorité à la construction dans laquelle le complément de lieu est prépositionnel, par exemple Luc peint un portrait sur la cloison par rapport à Luc peint la cloison d'un portrait;
- lorsqu'il existe un complément direct et un complément avec une des prépositions en ou entre, la construction dans laquelle apparaît ce dernier a priorité par rapport aux éventuelles autres constructions qui comportent un autre complément prépositionnel, par exemple Luc ventile le courrier en quatre tas par rapport à Luc ventile le courrier dans les services.

# G.1.4 Numérotation des arguments

Presque tous les critères font référence à un des arguments syntaxiques de la construction de base à travers une numérotation. Les arguments syntaxiques sont le sujet et les compléments essentiels. Ils sont supposés être numérotés à partir de 0 et conformément à l'ordre (ou à un des ordres possibles) des compléments dans la construction. Le sujet porte donc le numéro 0. De plus, on place les compléments directs avant les compléments indirects lorsque cet ordre est acceptable : Luc formule ses réflexions à Marie plutôt que Luc formule à Marie ses réflexions. Ces principes laissent parfois le choix entre plusieurs numérotations. Dans ce cas, l'arbre de classement tente de prévoir toutes les numérotations recevables, quitte à indiquer à la fin qu'il faut inverser deux numéros. Les prépositions éventuelles introduisant des compléments essentiels sont indicées par le numéro correspondant. Les groupes nominaux ou propositions constituant les arguments syntaxiques sont symbolisés par N indicé par le numéro. Ainsi, dans Luc formule ses réflexions à Marie, le symbole N1 représente ses réflexions, Prép2 symbolise à et N2 symbolise Marie.

#### G.1.5 Critères

Les critères utilisés dans l'arbre correspondent à des propriétés syntaxiques et sémantiques de l'entrée à classer. La plupart prennent la forme d'un des intitulés décrits dans la documentation des propriétés (cf. annexe E), par exemple

 $N1 =: Qu \ Pind \ qui \ indique \ la possibilité d'une complétive objet à l'indicatif en position <math>N1$ . D'autres sont des formules booléennes sur de tels intitulés (cf. 5.2.2): par exemple,  $(N1 =: Qu \ Pind)$  ou  $(N1 =: Qu \ Psubj)$  indique la possibilité d'une complétive objet à l'indicatif ou au subjonctif. Les quelques intitulés qui ne sont pas explicitement documentés utilisent les mêmes notations que les autres. Il faut appliquer successivement entre 2 et 14 critères pour déterminer à quelle classe appartient une entrée. Chaque étape propose un choix entre plusieurs critères exclusifs les uns des autres. Lorsqu'il y en a deux, ils sont souvent la négation logique l'un de l'autre. Par exemple, le critère associé à  $(N1 =: Qu \ Pind)$  ou  $(N1 =: Qu \ Psubj)$  est sa négation non  $(N1 =: Qu \ Pind)$  et non  $(N1 =: Qu \ Psubj)$ .

### G.1.6 Critères distributionnels

Beaucoup de critères contiennent le symbole =: et indiquent une valeur que peut prendre un des éléments de la construction de base (ou parfois plusieurs valeurs). Ainsi, N0 =: N-hum indique que le sujet N0 peut prendre comme valeur un groupe nominal N-hum dénotant une entité non humaine. Un tel critère n'indique pas une valeur exclusive : si le sujet peut aussi prendre d'autres valeurs, cela n'empêche pas que le critère donne un résultat positif. La seule exception à cette convention est le symbole Npl obl qui désigne un groupe nominal obligatoirement pluriel ou à sens collectif. Le symbole <E> représente l'absence de forme explicite, par exemple l'absence de préposition. Le symbole # se lit «différent de» et précède une ou plusieurs valeurs que l'élément peut ne pas prendre. Ainsi, Prép2 # à indique que la préposition peut avoir une valeur autre que à. Le critère Prép2 # <E> indique que la préposition peut avoir une forme explicite. Le critère non (Prép2 # <E>) indique qu'aucune préposition explicite ne peut apparaître en cette position.

## **G.1.7** Variantes de formulation

Un même critère peut généralement être formulé de plusieurs façons (cf. 5.2.2) : par exemple, dans le contexte des verbes transitifs directs à deux arguments, la possibilité d'une complétive objet à l'indicatif peut être notée N1 =: Qu Pind ou N0 V Qu Pind. La formulation choisie dans l'arbre de classement n'est pas toujours la même que celle choisie dans les intitulés des propriétés décrites dans les tables.

#### G.1.8 Résultat du classement

À l'issue de l'application des critères, l'arbre indique la classe <sup>1</sup> à laquelle appartient l'entrée. Dans certains cas, il indique en outre une ou plusieurs propriétés additionnelles que doit posséder l'entrée et qui n'ont pas été vérifiées dans les critères qui ont mené à cette branche. Par exemple, la branche menant à la classe 39 passe uniquement par 4 nœuds de l'arbre :

<sup>1.</sup> La notation \_part indique qu'il existe plusieurs chemins menant à cette même classe.

```
3 arguments \rightarrow Prép1 =: \langle E \rangle \rightarrow Prép2 =: \langle E \rangle \rightarrow non (N2 =: V0-inf W) Mais elle indique comme propriétés additionnelles : non (N1 =: V0-inf W) et non (Prép2 # \langle E \rangle+comme)
```

En d'autres termes, les auteurs du Lexique-Grammaire ont constaté lors de leur travail que toutes les entrées qui vérifient à la fois les 4 propriétés ci-dessus vérifient également ces propriétés additionnelles.

# G.2 Arbre de classement des verbes

FIGURE G.1: Arbre de classement des verbes (1)

```
3 arguments
 Prép1 =: <E>
   _Prép2 =: <E>
    \_ non (N2 =: VO-inf W)
     ____non (N1 =: V0-inf W) et non (Prép2 # <E>+comme)......39
   _non (Prép2 =: <E>)
     (N2 =: Qu Pind) ou (N2 =: Qu Psubj) ou (N2 =: V1-inf W) ou (N2 =: V0-inf
      __non (N1 =: Qu Pind) et non (N1 =: Qu Psubj) et non (N1 =: V0-inf W)
        __non (Prép2 # à)......11
        __non (Prép2 # de) ...... 13
     non (N2 =: Qu Pind) et non (N2 =: Qu Psubj) et non (N2 =: V1-inf W) et
     non (N2 =: VO-inf W)
       _(N1 =: Qu Pind) ou (N1 =: Qu Psubj) ou (N1 =: si P ou si P)
        ___non (Prép2 # à)
          __ N2 =: Nhum.....9
          _ non (N2 =: Nhum) ...... 10_part
      _non (N1 =: Qu Pind) et non (N1 =: Qu Psubj) et non (N1 =: si P ou si
       P) et non (N1 =: V0-inf W)......voir Fig. G.3
 _non(Prép1 =: <E>)
   (N2 =: Qu Pind) ou (N2 =: Qu Psubj) ou (N2 =: V1-inf W)
    __(N1 =: Qu Pind) ou (N1 =: Qu Psubj)
     non (N1 =: Qu Pind) et non (N1 =: Qu Psubj)
      _(Prép1 # avec+pour) ou (Prép2 # à)
       \_ non (N2 =: Qu Pind) et non (N2 =: Qu Psubj) et non (N2 =: V1-inf W) et non
    (N2 =: si P ou si P)
     _(N1 =: Qu Pind) ou (N1 =: Qu Psubj)
       non (Prép1 # à)
       _non (Prép1 # de)
       _non (N1 =: Qu Pind) et non (N1 =: Qu Psubj) et non (N1 =: V2-inf W)
      __ (N2 =: VO-inf W)
       \_ non (N2 =: VO-inf W)
        _ (N1 lieu source de N0) et (N2 lieu de destination de N0)
         __non (N1 =: V0-inf W) et non (N0 V N1 et N2)......35L
        _non (N1 lieu source de N0) ou non (N2 lieu de destination de N0)
         335
         FIGURE G.2: Arbre de classement des verbes (2)
```




FIGURE G.3: Arbre de classement des verbes (3)

```
2 arguments
 _Prép1 # <E>
   _(N1 =: Qu Pind) ou (N1 =: Qu Psubj)
     _(Prép1 # à) et (Prép1 # de)
      igspace non (N1 = où) et non (N1 lieu de N0) et non (N0 et N1 V) \dots 35R_{	ext{part}}
     _non (N1 =: Qu Pind) et non (N1 =: Qu Psubj)
      N1 =: VO-inf W
      \_ non (N1 =: VO-inf W)
       _(NO =: Qu P) et [extrap]
        \bot non (NO rendre N1 V-adj) et non (NO rendre N1 plus V-adj)....5_part
       _non (NO =: Qu P) ou non [extrap]
         _ N1 = où
           __NO et N1 V
            __non (NO et N1 V)
             _(N1 lieu source de N0) ou (N1 lieu statique de N0)
               \_ N1 V de N0......34L0
               __non (N1 V de N0)
                oxdot N1 lieu source de N0\dots 35{
m LS}
                ldsymbol{ldsymbol{ldsymbol{ldsymbol{eta}}}} N1 lieu statique de N0\ldots35\mathbf{ST}
             _non (N1 lieu de N0)
              non (N1 = où) et non (N1 lieu de N0)
           __Prép1  # à+<E>
             __ NO et N1 V
              __non (Prép1 # à).......33
 __non (Prép1 # <E>)
   _(N1 =: Qu Pind) ou (N1 =: Qu Psubj) ou (N1 = :si P ou si P) ou (N1 =:
    combien P)
     _{-} (N1 =: Qu Psubj) et (Qu Psubj =: Qu Ni Vsubj W = (Ni) (de Vi-inf W)) \dots 12
    __non (Qu Psubj =: Qu Ni Vsubj W = (Ni) (de Vi-inf W))
      ___ NO =: V1-inf W
        __ (NO =: Qu P) et (N1 =: Nhum) et non (N1 =: Nconc) et non (N1 =:
          _ non (NO =: V1-inf W)......6
   _non (N1 =: Qu Pind) et non (N1 =: Qu Psubj) et non (N1 = :si P ou si P) et
    non (N1 =: combien P) .......voir Fig. G.5
```

FIGURE G.4: Arbre de classement des verbes (4)

```
2 arguments (suite)
      _N1 =: V0-inf W.......1_part
      non (N1 =: VO-inf W)
        __ NO =: Qu P
           (NO rendre N1 V-adj) ou (NO rendre N1 plus V-adj)
             __(N1 =: Nhum) et non (N1 =: Nconc)
              ____non [extrap]......4_part
             __non (N1 =: Nhum) ou (N1 =: Nconc)
              __ [passif par]......32RA_part
            non (NO rendre N1 V-adj) et non (NO rendre N1 plus V-adj)
             __ [extrap]......5_part
             _non [extrap]
              __ (N1 =: Nhum) et non (N1 =: Nconc)......4_part
         \_non (NO =: Qu P)
            [passif par]
             _thème N1
               _(NO lieu source de N1) ou (NO lieu de destination de N1) ou
                 (NO lieu statique de N1)......38L0_part
                (N1 lieu source de N0) ou (N1 lieu de destination de N0)
                 ou (N1 lieu statique de N0) ou (N1 lieu de passage de N0)
                _non (NO lieu de N1) et non (N1 lieu de N0)......32R3
             _non (thème N1)
               __N1 apparition......32A
                \_ N1 disparition......f 32D
               __non (N1 apparition) et non (N1 disparition)
                  __N1 =: Npl obl......32PL
                  _ non (N1 =: Npl obl).....voir Fig. G.6
            non [passif par]
            __(NO lieu source de N1) ou (NO lieu de destination de N1) ou (NO
              lieu statique de N1)
               __N1 =: N-hum......38L0_part
             _(N1 lieu source de N0) ou (N1 lieu de destination de N0) ou (N1
              lieu statique de NO) ou (N1 lieu de passage de NO)
               _N1 =: N-hum......38L1_part
             _non (NO lieu de N1) et non (N1 lieu de N0)\dots 32 NM
```

FIGURE G.5: Arbre de classement des verbes (5)




FIGURE G.6: Arbre de classement des verbes (6)

# Annexe G Arbre de classement des verbes distributionnels

| 1 argument                      |     |
|---------------------------------|-----|
| NO =: N-hum                     | 31R |
| non (NO =: N-hum) et NO =: Nhum | 31H |

FIGURE G.7: Arbre de classement des verbes (7)